

**KLASIFIKASI SPERMA MANUSIA BERDASARKAN MORFOLOGI
MENGUNAKAN *DENSELY CONNECTED CONVOLUTIONAL NETWORKS***

(Skripsi)

Oleh

IRMA AZIZAH

2017051038



FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM

UNIVERSITAS LAMPUNG

BANDAR LAMPUNG

2024

**KLASIFIKASI SPERMA MANUSIA BERDASARKAN MORFOLOGI
MENGUNAKAN *DENSELY CONNECTED CONVOLUTIONAL NETWORKS***

Oleh

**Irma Azizah
2017051038**

Skripsi

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

Pada

**Jurusan 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 *DENSELY CONNECTED CONVOLUTIONAL NETWORKS*

Oleh

IRMA AZIZAH

Infertilitas, menurut *World Health Organization* (WHO), didefinisikan sebagai ketidakmampuan untuk hamil setelah 12 bulan hubungan seksual teratur tanpa perlindungan, yang memengaruhi 8–12% pasangan usia reproduksi. Faktor pria menyumbang sekitar 50% dari seluruh kasus infertilitas. Salah satu metode untuk menilai faktor pria adalah analisis morfologi sperma, namun variasi bentuk sperma yang signifikan sering kali mempersulit proses diagnosis. Penggunaan sistem otomatis dalam klasifikasi sperma dapat mengatasi keterbatasan seleksi manual yang cenderung kurang akurat. Penelitian ini bertujuan untuk mengimplementasikan arsitektur CNN DenseNet169 dalam pengklasifikasian sperma berdasarkan morfologi serta mengevaluasi kinerja model pada berbagai skema pembagian data. Eksperimen dilakukan pada *dataset* HuSHem dan SCIAN dengan pembagian data dalam rasio 80:10:10, 70:25:5, dan 60:20:20. Hasil menunjukkan bahwa pada *dataset* HuSHem, akurasi *testing* tertinggi sebesar 97,78% dicapai dengan rasio 70:25:5, sementara pada *dataset* SCIAN, akurasi tertinggi sebesar 78,79% dicapai dengan rasio yang sama.

Kata kunci : Sperma Manusia, *Machine Learning*, CNN, DenseNet.

ABSTRACT

CLASSIFICATION OF HUMAN SPERM BASED ON MORPHOLOGY USING DENSELY CONNECTED CONVOLUTIONAL NETWORKS

By

IRMA AZIZAH

Infertility, according to the World Health Organization (WHO), is defined as the inability to conceive after 12 months of regular unprotected sexual intercourse, which affects 8–12% of couples of reproductive age. Male factors account for about 50% of all infertility cases. One method to assess male factors is sperm morphology analysis, but significant variations in sperm shape often complicate the diagnosis process. The use of an automated system in sperm classification can overcome the limitations of manual selection which tends to be less accurate. This study aims to implement the DenseNet169 CNN architecture in sperm classification based on morphology and evaluate the performance of the model on various data sharing schemes. Experiments were conducted on the HuSHem and SCIAN datasets with data sharing in ratios of 80:10:10, 70:25:5, and 60:20:20. The results show that in the HuSHem dataset, the highest testing accuracy of 97.78% was achieved with a ratio of 70:25:5, while in the SCIAN dataset, the highest accuracy of 78.79% was achieved with the same ratio.

Keywords: Human Sperm, Machine Learning, CNN, DenseNet.

Judul Skripsi : **KLASIFIKASI SPERMA MANUSIA
BERDASARKAN MORFOLOGI
MENGUNAKAN *DENSELY CONNECTED
CONVOLUTIONAL NETWORKS***

Nama Mahasiswa : **Irma Azizah**

Nomor Pokok Mahasiswa : 2017051038

Program Studi : SI Ilmu Komputer

Jurusan : Ilmu Komputer

Fakultas : Matematika dan Ilmu Pengetahuan Alam



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

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

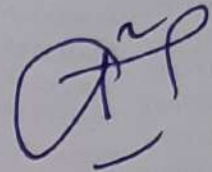
2. Ketua Jurusan Ilmu Komputer

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

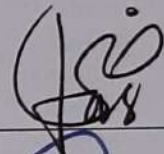
MENGESAHKAN

1. Tim Penguji

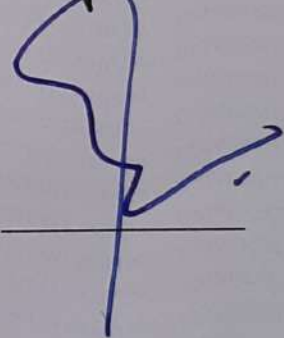
Ketua : Dr. Aristoteles, S.Si., M.Si.



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



Penguji Utama : Prof. Admi Syarif, 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 : 3 Desember 2024

PERNYATAAN

Saya yang bertanda tangan di bawah ini, menyatakan bahwa skripsi saya yang berjudul **“Klasifikasi Sperma Manusia Berdasarkan Morfologi Menggunakan *Densely Connected Convolutional Networks*“** 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, 3 Desember 2024

Penulis,



Irma Azizah

NPM. 2017051038

RIWAYAT HIDUP



Penulis lahir di Kota Solok pada tanggal 10 Desember 2000 sebagai anak pertama dari pasangan Bapak Jon Mawardi dan Ibu Afda Hayani. Penulis lulus pendidikan formal di SD Negeri 02 Percontohan pada tahun 2013, kemudian melanjutkan di MTs Negeri 1 Bukittinggi dan selesai pada tahun 2016. Penulis kemudian melanjutkan pendidikan menengah atas di SMA Negeri 1 Bukittinggi dan lulus pada tahun 2019.

Pada tahun 2020 penulis terdaftar sebagai mahasiswa Jurusan Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung melalui jalur SBMPTN. Selama menjadi mahasiswa penulis aktif mengikuti berbagai kegiatan di antaranya sebagai berikut.

1. Mengikuti Kursus Pemrograman Berorientasi Objek pada Program Kredensial Mikro Mahasiswa Indonesia (KMMI) tahun 2021.
2. Melaksanakan KKN Mandiri di Desa Negara Batin, Kota Agung Barat, Kabupaten Lampung Selatan pada tahun 2023.
3. Mengikuti program *Student Mobility* di Universiti Malaya pada tahun 2023.

MOTTO

“Mukmin yang kuat lebih baik dan lebih dicintai Allah daripada mukmin yang lemah; dan pada keduanya ada kebaikan.”

(HR. Muslim, Ahmad, Ibnu Mâjah, an-Nasâ-I, at-Thahawi, Ibnu Abi Ashim)

“The only way to achieve the impossible is to believe it is possible.”

- Charles Kingsleigh

(Dari Novel *Alice in Wonderland*)

“It's time for you to look inward, and start asking yourself the big questions. Who are you? And what do you want?”

- Iroh

(Dari *Avatar: The Last Airbender Series*)

“ It's mostly a matter of changing your perspective.”

- Chris Hadfield

(Purnawirawan Antariksawan, Insinyur, dan Mantan Pilot Tempur *Royal Canadian Air Force*)

PERSEMBAHAN

Alhamdulillahirobbilalamin

Dengan rasa syukur kepada Allah Subhanahu Wa Ta'ala atas Ridho, Rahmat, dan Karunia-Nya sehingga saya dapat menyelesaikan skripsi ini. Shalawat serta salam selalu tercurahkan kepada Nabi Muhammad Shallallahu Alaihi Wasallam.

Kupersembahkan karya ini kepada:

Kedua Orang Tuaku Tercinta

Ibu dan Ayah, terima kasih selalu atas doa dan kasih sayang yang tiada terhingga. Terima kasih atas segala dukungan baik moril ataupun materi. Terima kasih atas doa yang tidak pernah lelah diberikan, terima kasih atas segala keringat dan air mata.

Terima kasih untuk selalu percaya. Terima kasih untuk adikku tersayang atas dukungan dan do'a yang diberikan kepadaku.

Terima kasih juga untuk semua pihak yang terlibat dalam pembuatan skripsi ini.

Semoga Allah senantiasa membalas setiap kebaikan kalian.

Almamater Tercinta, Universitas Lampung dan Jurusan Ilmu Komputer

Tempat bernaung mengemban ilmu untuk bekal kehidupan.

SANWACANA

Puji syukur penulis ucapkan kehadirat Allah Subhanahu Wata'ala, karena atas rahmat dan hidayah-Nya sehingga penulis dapat menyelesaikan skripsi ini. Shalawat serta salam semoga senantiasa tercurahkan kepada junjungan Nabi Muhammad Shallallahu Alaihi Wasallam yang penulis harapkan syafaatnya di hari akhir kelak. Skripsi dengan judul **“Klasifikasi Sperma Manusia Berdasarkan Morfologi Menggunakan *Densely Connected Convolutional Networks*”** adalah salah satu syarat untuk memperoleh gelar sarjana komputer pada Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

Dalam penyusunan skripsi ini, penulis mendapat bantuan, dukungan dan motivasi dari berbagai pihak. Oleh karena itu, penulis mengucapkan terima kasih yang sebesar besarnya kepada:

1. Kedua orang tuaku tercinta, Ayah dan Ibu yang selalu mendoakan, mendukung, memotivasi dan memberikan kasih sayang pada penulis.
2. Bapak Dr. Aristoteles, S.Si., M.Si., selaku dosen pembimbing utama yang selalu membimbing, memberikan arahan, motivasi, masukan serta saran, dalam penyelesaian skripsi ini.
3. Ibu Dewi Asiah Shofiana, S.Komp., M.Kom., selaku dosen pembimbing kedua yang selalu membimbing, memberikan arahan, masukan dan saran dalam penyelesaian skripsi ini.
4. Bapak Prof. Admi Syarif, Ph.D., selaku dosen pembahas yang telah memberikan saran dan masukan yang bermanfaat dalam perbaikan skripsi ini.

5. Bapak Dwi Sakethi, S.Si., M.Kom., selaku Ketua Jurusan Ilmu Komputer FMIPA Universitas Lampung.
6. Ibu Anie Rose Irawati, S.T., M.Cs., selaku Sekretaris Jurusan Ilmu Komputer FMIPA Universitas Lampung.
7. Bapak, Ibu Dosen dan semua Staf Jurusan Ilmu Komputer FMIPA Universitas Lampung yang telah memberikan banyak ilmu dan wawasan baru kepada penulis dan telah membantu segala urusan administrasi yang penulis butuhkan.
8. Adik-adikku yang selalu mendukung, memberikan do'a dan semangat kepada penulis.
9. Teman seperjuangan semasa kuliah, Safiira, Nuk, Putri, Yulia, Nafasya, Fitriah dan teman teman lainnya yang tidak bisa penulis sebutkan satu persatu, terima kasih karena selalu ada, terima kasih telah mendukung, mendoakan, membantu, dan mewarnai hari penulis selama masa perkuliahan.
10. Teman-teman seperbimbingan, Sarah dan Silvia yang telah memberikan bantuan, masukan, dukungan, dan menemani selama pengerjaan skripsi semoga Allah selalu memudahkan.
11. Teman-teman Ilmu Komputer angkatan 2020 yang menjadi teman satu angkatan selama menjalankan masa studi.

Akhir kata, penulis menyadari bahwa skripsi ini masih jauh dari kesempurnaan, akan tetapi penulis berharap skripsi ini dapat berguna dan bermanfaat bagi semua. Semoga dengan bantuan dan dukungan yang diberikan mendapat balasan pahala di sisi Allah Subhanahu Wa Ta'ala. Aamiin.

Bandar Lampung, 3 Desember 2024

Penulis,



Irma Azizah

NPM. 2017051038

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	8
2.3 <i>Digital Image</i>	10
2.4 <i>Machine Learning</i>	11
2.5 <i>Deep Learning</i>	12
2.6 <i>Convolutional Neural Network (CNN)</i>	14
2.6.1 <i>Convolutional Layer</i>	15
2.6.2 <i>Activation Function</i>	16
2.6.3 <i>Optimizer</i>	17
2.6.4 <i>Hyperparameter</i>	17

2.6.5	<i>Pooling</i>	19
2.6.6	<i>Fully Connected Layer</i>	20
2.7	Densenet	20
2.8	Confusion Matrix	23
2.9	Augmentasi Data	26
2.10	Statistika Deskriptif	29
III.	METODOLOGI PENELITIAN	32
3.1	Tempat dan Waktu Penelitian	32
3.2	Data dan Alat	33
3.3	Tahap Penelitian	34
IV.	PEMBAHASAN	40
4.1	Persiapan Data	40
4.2	Preprocessing	40
4.3	Pembagian Data	42
4.3.1	Pembagian Data HusHem	42
4.3.2	Pembagian Data SCIAN	43
4.4	Pelatihan Model CNN	45
4.5	Hasil Klasikasi Model CNN	47
4.5.1	Hasil <i>Training</i> Model pada Data HusHem	64
4.5.2	Hasil <i>Training</i> Model pada Data SCIAN	67
V.	SIMPULAN DAN SARAN	81
5.1	Simpulan	81
5.2	Saran	82
	DAFTAR PUSTAKA	84

DAFTAR TABEL

Tabel	Halaman
1. Penelitian Terdahulu Terkait Klasifikasi Sperma Manusia Menggunakan CNN.	6
2. Waktu Penelitian.	32
3. Hyperparameter <i>Dataset</i> HusHem.	38
4. Hyperparameter <i>Dataset</i> SCIAN.	38
5. Distribusi Data HusHem.	43
6. Distribusi Data HusHem Setelah Diaugmentasi.	43
7. Distribusi Data SCIAN.	44
8. Distribusi Data SCIAN dengan Teknik Augmentasi Pada Data <i>Training</i>	44
9. Distribusi Data SCIAN dengan Teknik Augmentasi pada Semua Data.	45
10. Hasil Pelatihan Model pada Data Tanpa Augmentasi.	47
11. Ukuran Statistik Deskriptif Hasil Pelatihan Model pada Data HuSHem Tanpa Augmentasi.	49
12. Ukuran Statistik Deskriptif Hasil Pelatihan Model pada Data SCIAN Tanpa Augmentasi.	50
13. Hasil Perbandingan <i>Learning rate</i> pada Data <i>Training</i> yang Diaugmentasi.	51
14. Hasil Pelatihan Model pada Data <i>Training</i> yang Diaugmentasi dengan <i>Learning rate</i> 0,001.	53
15. Ukuran Statistik Deskriptif Hasil Pelatihan Model pada Data HuSHem <i>Training</i> yang Diaugmentasi dengan <i>Learning rate</i> 0,001.	56

16. Ukuran Statistik Deskriptif Hasil Pelatihan Model pada Data SCIAN <i>Training</i> yang Diaugmentasi dengan <i>Learning rate</i> 0,001.	56
17. Hasil Perbandingan <i>Learning rate</i> pada Semua Data yang Diaugmentasi.	57
18. Hasil Pelatihan Model pada Semua Data yang Diaugmentasi dengan <i>Learning rate</i> 0,001.	59
19. Ukuran Statistik Deskriptif Hasil Pelatihan Model pada Semua Data HuSHem yang Diaugmentasi dengan <i>Learning rate</i> 0,001.	62
20. Ukuran Statistik Deskriptif Hasil Pelatihan Model pada Semua Data SCIAN yang Diaugmentasi dengan <i>Learning rate</i> 0,001.	62
21. Hasil Akurasi Tertinggi untuk Masing-Masing Skema.	63
22. Nilai <i>Precision</i> , <i>Recall</i> , <i>F1 score</i> , dan Akurasi pada Klasifikasi Data HuSHem.	77
23. Nilai <i>Precision</i> , <i>Recall</i> , <i>F1 score</i> , dan Akurasi pada Klasifikasi Data SCIAN.	78
24. Perbandingan Model.	78

DAFTAR GAMBAR

Gambar	Halaman
1. Diagram spermatozoa manusia (Alves et al., 2020).	8
2. Jenis-jenis kelainan pada sperma manusia (Chang et al., 2017).	9
3. Pendekatan <i>Deep Learning</i> menggunakan hierarki representasi (Wani et al., 2020).	13
4. Arsitektur <i>Convolutional Neural Network</i> (https://medium.com).	14
5. Operasi konvolusi (Bouguezzi et al., 2021).	16
6. Jenis <i>pooling</i> (Taye, 2023).	20
7. DenseNet (Radwan, 2019).	21
8. Arsitektur DenseNet (Huang et al., 2017).	22
9. <i>Confusion matrix</i> (Krüger, 2016).	24
10. Alur penelitian.	35
11. <i>Dataset</i> HusHem.	36
12. <i>Dataset</i> SCIAN.	36
13. <i>Cropping</i> Citra	41
14. Grafik akurasi dan <i>loss dataset</i> HuSHem yang diaugmentasi hanya di data <i>training</i> berdasarkan skenario pertama	64
15. Grafik akurasi dan <i>loss dataset</i> HuSHem yang diaugmentasi hanya di data <i>training</i> berdasarkan skenario kedua	65
16. Grafik akurasi dan <i>loss dataset</i> HuSHem yang diaugmentasi hanya di data <i>training</i> berdasarkan skenario ketiga	65

17. Grafik akurasi dan <i>loss dataset</i> HuSHem yang diaugmentasi pada semua data berdasarkan skenario pertama	66
18. Grafik akurasi dan <i>loss dataset</i> HuSHem yang diaugmentasi pada semua data berdasarkan skenario kedua	67
19. Grafik akurasi dan <i>loss dataset</i> HuSHem yang diaugmentasi pada semua data berdasarkan skenario ketiga	67
20. Grafik akurasi dan <i>loss dataset</i> SCIAN yang diaugmentasi hanya di data <i>training</i> berdasarkan skenario pertama	68
21. Grafik akurasi dan <i>loss dataset</i> SCIAN yang diaugmentasi hanya di data <i>training</i> berdasarkan skenario kedua	68
22. Grafik akurasi dan <i>loss dataset</i> SCIAN yang diaugmentasi hanya di data <i>training</i> berdasarkan skenario ketiga	69
23. Grafik akurasi dan <i>loss dataset</i> SCIAN yang diaugmentasi pada semua data berdasarkan skenario pertama	69
24. Grafik akurasi dan <i>loss dataset</i> SCIAN yang diaugmentasi pada semua data berdasarkan skenario kedua	70
25. Grafik akurasi dan <i>loss dataset</i> SCIAN yang diaugmentasi pada semua data berdasarkan skenario ketiga	70
26. <i>Confusion matrix dataset</i> HuSHem yang diaugmentasi hanya di data <i>training</i> berdasarkan skenario pertama	71
27. <i>Confusion matrix dataset</i> HuSHem yang diaugmentasi hanya di data <i>training</i> berdasarkan skenario kedua	71
28. <i>Confusion matrix dataset</i> HuSHem yang diaugmentasi hanya di data <i>training</i> berdasarkan skenario ketiga	72
29. <i>Confusion matrix dataset</i> HuSHem yang diaugmentasi pada semua data berdasarkan skenario pertama	72
30. <i>Confusion matrix dataset</i> HuSHem yang diaugmentasi pada semua data berdasarkan skenario kedua	73
31. <i>Confusion matrix dataset</i> HuSHem yang diaugmentasi pada semua data berdasarkan skenario ketiga	73

32. <i>Confusion matrix dataset</i> SCIAN yang diaugmentasi hanya di data <i>training</i> berdasarkan skenario pertama	74
33. <i>Confusion matrix dataset</i> SCIAN yang diaugmentasi hanya di data <i>training</i> berdasarkan skenario kedua	74
34. <i>Confusion matrix dataset</i> SCIAN yang diaugmentasi hanya di data <i>training</i> berdasarkan skenario ketiga	75
35. <i>Confusion matrix dataset</i> SCIAN yang diaugmentasi pada semua data berdasarkan skenario pertama	75
36. <i>Confusion matrix dataset</i> SCIAN yang diaugmentasi pada semua data berdasarkan skenario kedua	76
37. <i>Confusion matrix dataset</i> SCIAN yang diaugmentasi pada semua data berdasarkan skenario ketiga	76

I. PENDAHULUAN

1.1 Latar Belakang

World Health Organization (WHO) mendefinisikan infertilitas sebagai ketidakmampuan untuk hamil setelah setidaknya 12 bulan melakukan hubungan seksual secara teratur dan tanpa perlindungan. Infertilitas diperkirakan memengaruhi 8–12% pasangan dalam kelompok usia reproduksi (Agarwal et al., 2021). Secara keseluruhan, faktor pria secara signifikan berkontribusi sekitar 50% dari semua kasus infertilitas (Leslie et al., 2024). Penilaian faktor-faktor pria dalam infertilitas melibatkan pemeriksaan sampel air mani yang disediakan di laboratorium, dengan mempertimbangkan parameter seperti morfologi sperma, konsentrasi, dan gerak (Yüzkat et al., 2021). Kelainan morfologis sperma, yang terkait dengan cacat dalam bentuk dan ukuran sel sperma, memiliki pengaruh kritis pada infertilitas pria. Oleh karena itu, mengklasifikasikan bentuk sperma dengan akurat merupakan langkah awal yang penting dalam mendiagnosis infertilitas pria. Namun, variasi dalam bentuk sperma dapat membuat analisis menjadi rumit dan menimbulkan kesulitan dalam proses diagnosis (Yüzkat et al., 2021).

Saat ini, pemilihan manual untuk sperma yang sehat dapat menimbulkan masalah karena tidak bisa seakurat sistem otomatis. Di sisi lain, sistem otomatis dapat menghemat tenaga kerja, dan laboratorium tidak perlu menyediakan teknisi yang terampil untuk pemilihan sperma dalam proses injeksi sperma intrasitoplasmik

(Mashaal et al., 2023). Selain itu, klasifikasi sperma merupakan tugas yang kompleks dan menantang karena adanya keberagaman bentuk-bentuk sperma yang sulit diidentifikasi bahkan oleh ahli. Keberagaman tersebut diantaranya merupakan bentuk, ukuran, dan tekstur yang sangat kompleks sehingga tugas tersebut menjadi sangat sulit bagi para ahli. Selain perbedaan intra-kelas, terdapat juga kesamaan antar-kelas (Iqbal et al., 2020). Sebagai contoh, sebuah kepala *amorphous* yang memanjang mirip dengan kepala *tapered* atau berbentuk pir seperti kepala *pyriform*, dan kepala *tapered* yang menyempit di dekat ekor identik dengan kepala *pyriform* (Iqbal et al., 2020).

Kemungkinan faktor gaya hidup yang dapat mempengaruhi penurunan nilai spermatozoa manusia telah dianalisis beberapa dekade terakhir (Naseem et al., 2023). Studi ini mencakup pemantauan pola hidup seperti kebiasaan makan, paparan zat kimia berbahaya, dan aktivitas fisik (Naseem et al., 2023). Namun, interpretasi hasil yang akurat dan efisien dari data tersebut dapat menjadi tantangan (Naseem et al., 2023). Penerapan *deep learning* dapat menjadi solusi yang efektif dalam mengatasi kompleksitas data dan mencegah keputusan diagnostik yang salah (Reddy & Juliet, 2019). *Deep learning* merupakan bagian dari *machine learning*, yang telah memberikan hasil yang sangat baik dalam banyak bidang non-medis (Reddy & Juliet, 2019). *Deep learning* mampu mempelajari fitur representasi dari data mentah. Metode *deep learning* telah diterapkan secara luas dalam bidang diagnosis kerusakan, seperti *Deep Belief Network (DBN)*, *Sparse Autoencoder (SAE)*, dan *Convolutional Neural Network (CNN)* (Wen et al., 2020). Metode *deep learning* memiliki potensi yang besar untuk mendiagnosis kerusakan karena mampu mengurangi efek dari fitur buatan tangan yang dirancang melalui proses ekstraksi fitur (Wen et al., 2020).

Deep learning dapat digunakan dalam menganalisis sperma manusia. *Deep learning* dapat diterapkan dalam mengekstrak dan memetakan fitur visual yang terdapat dalam citra sperma ke dalam kategori morfologi yang relevan (Spencer et al., 2022). Menurut para ahli, *deep learning* mengandalkan *Convolutional Neural*

Network (CNN) untuk memprediksi motilitas sperma dan morfologi sperma (Haugen et al., 2019). Penelitian mengenai morfologi sperma telah banyak dipublikasi. Salah satu diantaranya dilakukan oleh Tortumlu dan Ilhan. Penelitian tersebut menggunakan model MobileNet dan mendapatkan akurasi paling tinggi sekitar 77% untuk *dataset* Hushem dan 67% untuk *dataset* SCIAN (Tortumlu & Ilhan, 2020).

DenseNet memiliki keunggulan dibandingkan arsitektur CNN lainnya. Salah satunya yaitu penggunaan ulang fitur, yang memungkinkan DenseNet mempertahankan informasi dari lapisan sebelumnya. *Deep Learning* yang memanfaatkan algoritme CNN khususnya DenseNet telah banyak diimplementasikan pada bidang kesehatan. Salah satunya pada penelitian yang dilakukan oleh Breve F. (Breve, 2022) dengan judul *COVID-19 detection on Chest X-ray images: A comparison of CNN architectures and ensembles*. Penelitian tersebut menggunakan *dataset* COVIDx8B dengan 16,352 citra X-ray dada (CXR) dari pasien lebih dari 51 negara. Kemudian model yang digunakan, DenseNet169 dibandingkan dengan 21 arsitektur CNN lainnya untuk mendeteksi COVID-19. Hasil penelitian tersebut menunjukkan bahwa DenseNet169 mencapai akurasi 98.15% dan skor F1 98.12%, menjadikannya model CNN terbaik di antara model-model lain yang diuji.

Dengan demikian, dalam penelitian ini menekankan pada klasifikasi cacat atau kelainan dalam bentuk sperma manusia. Penelitian ini menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur DenseNet untuk melakukan klasifikasi morfologi sperma. Penelitian ini menggunakan dua *dataset*, yaitu HusHem dan SCIAN yang masing-masing merupakan *multi-class*. Pemilihan model ini karena DenseNet cenderung memiliki efek regularisasi yang lebih baik karena setiap lapisan memegang informasi dari lapisan sebelumnya, dan ini memungkinkan jaringan menjadi lebih tangguh terhadap *overfitting*. Selain itu, penelitian ini menggunakan tiga skema pembagian data. Pembagian data tersebut yaitu data *training*, *validation*, dan *test*. Data *training* digunakan untuk melatih

model, data *validation* digunakan untuk mengatur *hyperparameter* dan mencegah *overfitting* dengan memberikan umpan balik mengenai performa selama pelatihan, dan data *test* digunakan untuk menilai kinerja akhir model pada data yang benar-benar baru, memastikan bahwa model tidak hanya baik pada data yang sudah dilihatnya tetapi juga dapat diaplikasikan pada data yang belum pernah ditemui. Pembagian ini membantu menghindari bias dan memberikan evaluasi yang lebih akurat terhadap kemampuan model. Oleh karena itu, penelitian ini dilakukan dengan tujuan untuk mengevaluasi seberapa baik kinerja model ini dalam melakukan klasifikasi sperma manusia berdasarkan morfologi.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan, permasalahan yang dapat diidentifikasi adalah bagaimana mengukur kinerja model DenseNet untuk mengklasifikasi sperma manusia berdasarkan morfologi dengan menggunakan metode skema pembagian data.

1.3 Batasan Masalah

Untuk menjadikan penelitian lebih terarah, diperlukan pembatasan pada masalah. Batasan dalam penelitian ini mencakup hal-hal berikut.

- a. Penelitian ini menggunakan *dataset* HusHem yang terdiri dari 216 data dan SCIAN yang terdiri dari 1132 data. Objek dari *dataset* tersebut terdiri dari empat *class dataset* HusHem dengan format BMP, yaitu *normal*, *tapered*, *pyriform*, dan *amorphous* dan lima *class dataset* SCIAN (*SCIAN Gold-standard for Morphological Sperm Analysis*) dengan format TIF, yaitu *normal*, *tapered*, *pyriform*, *small*, dan *amorphous*.
- b. Menggunakan algoritme DenseNet dibuat dengan menggunakan *platform* Python dalam mengklasifikasikan data.
- c. Menggunakan teknik augmentasi pada data.

1.4 Tujuan

Berdasarkan rumusan masalah yang telah dijabarkan, tujuan dari penelitian ini adalah mengimplementasikan algoritme arsitektur CNN DenseNet dalam pengklasifikasian sperma manusia berdasarkan morfologi serta mengetahui hasil evaluasi kinerja model dalam pengklasifikasian sperma manusia berdasarkan skema pembagian data.

1.5 Manfaat

Manfaat dari penelitian ini adalah sebagai berikut.

- a. Berkontribusi pada pengembangan model masa depan yang lebih efisien dalam analisis sperma dalam konteks penelitian infertilitas pada pria.
- b. Sebagai referensi penggunaan model arsitektur DenseNet dalam identifikasi morfologi sperma manusia.

II. TINJAUAN PUSTAKA

2.1 Penelitian Terdahulu

Penelitian ini terkait erat dengan studi-studi sebelumnya, sehingga terlihat keterkaitan serta perbedaan antara subjek-subjek yang telah diteliti sebelumnya. Rangkuman dari penelitian sebelumnya dapat dilihat dalam Tabel 1.

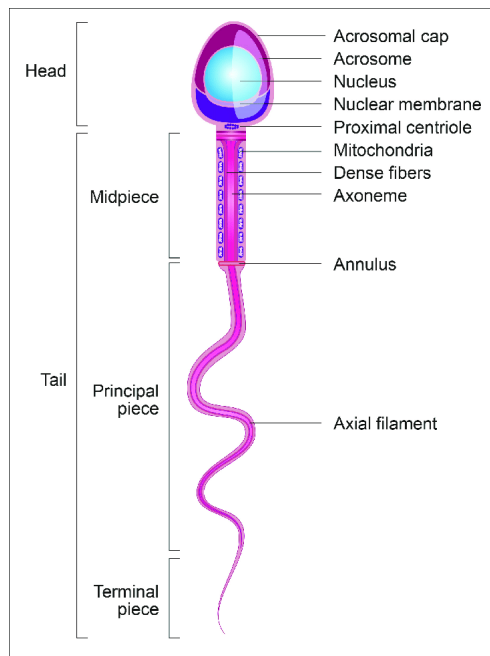
Tabel 1. Penelitian Terdahulu Terkait Klasifikasi Sperma Manusia Menggunakan CNN.

No	Judul	Metode	Data	Hasil
1	<i>A Dictionary Learning Approach for Human Sperm Heads Classification</i> (Shaker et al., 2017)	<i>Adaptive patch-based dictionary learning method (APDL)</i>	<i>Dataset HuSHem dengan jumlah 216 citra sel sperma (54 normal, 53 tapered, 57 pyriform, dan 52 amorphous) dan SCIAN dengan jumlah 1854 citra sel sperma (100 normal, 228 tapered, 76 pyriform, 72 small dan 656 amorphous).</i>	<i>Accuracy = 92.2%</i>

No	Judul	Metode	Data	Hasil
2	<i>The analysis of mobile platform based CNN networks in the classification of sperm morphology</i> (Tortumlu & Ilhan, 2020).	<i>Convolutional Neural Network (CNN):</i> MobileNet V1 dan MobileNet V2.	<i>Dataset</i> HuSHem dengan jumlah 216 citra sel sperma (54 normal, 53 tapered, 57 pyriform, dan 52 amorphous), SMIDS dengan jumlah 3000 citra sel sperma, dan SCIAN dengan jumlah 1854 citra sel sperma (100 normal, 228 tapered, 76 pyriform, 72 small dan 656 amorphous).	MobileNet V1: HuSHem accuracy = 75%, SMIDS accuracy = 88%, SCIAN accuracy = 67%. MobileNet V2: HuSHem accuracy = 77%, SMIDS accuracy = 87%, SCIAN accuracy = 66%.
3	<i>Multi-model CNN fusion for sperm morphology analysis</i> (Yüzkat et al., 2021).	Menggunakan pendekatan <i>fusion</i> berbasis <i>soft-voting</i> dan <i>hard-voting</i> pada enam model <i>Convolutional Neural Network (CNN)</i> .	<i>Dataset</i> HuSHem dengan jumlah 216 citra sel sperma (54 normal, 53 tapered, 57 pyriform, dan 52 amorphous), SMIDS dengan jumlah 3000 citra sel sperma, dan SCIAN dengan jumlah 1854 citra sel sperma (100 normal, 228 tapered, 76 pyriform, 72 small dan 656 amorphous).	HuSHem accuracy = 85.18%, SMIDS accuracy = 90.73%, SCIAN accuracy = 71.91%.
4	<i>Automated sperm morphology analysis approach using a directional masking technique</i> (Ilhan et al., 2020).	<i>SVM Classification</i> (non-linear kernel).	<i>Dataset</i> HuSHem dengan jumlah 216 citra sel sperma (54 normal, 53 tapered, 57 pyriform, dan 52 amorphous), SMIDS dengan jumlah 3000 citra sel sperma.	HuSHem accuracy = 86.6%. SMIDS: accuracy = 85.7%.


2.2 Sperma

Sperma manusia terdiri dari tiga bagian utama yang mencakup ukuran kepala (*head*), bagian tengah (*midpiece*) dan struktur ekor (*tail*) (Shaker et al., 2016). Diagram sperma manusia dapat dilihat pada Gambar 1.



Gambar 1. Diagram spermatozoa manusia (Alves et al., 2020).

Dalam biologi, morfologi merujuk pada kajian mengenai bentuk dan struktur organisme (Aronoff & Fudeman, 2011). Morfologi sperma dinilai berdasarkan karakteristik seperti luas kepala, keliling, lebar, panjang, rasio lebar terhadap panjang, eliptisitas, faktor bentuk, tiga nilai Fourier pertama (F1, F2, dan F3) simetri samping, simetri anterior-posterior, koefisien hidrodinamik, serta lebar dasar sperma (jarak antara titik-titik di bagian dasar kepala sperma) (Beletti et al., 2005). Morfologi sperma dianggap sebagai salah satu indikator untuk memprediksi kesuburan (Chang et al., 2017). Sel sperma yang abnormal umumnya memiliki potensi pembuahan yang lebih rendah (Chang et al., 2017). Karakteristik sperma abnormal dapat dilihat pada Gambar 2.



Gambar 2. Jenis-jenis kelainan pada sperma manusia (Chang et al., 2017).

Menurut WHO (World Health Organization, 2010), kategori cacat dalam setiap bagian sperm adalah sebagai berikut.

1. Cacat Kepala

Kepala sperma bisa memiliki berbagai bentuk cacat, seperti terlalu besar (*large*) atau terlalu kecil (*small*), meruncing (*tapered*), berbentuk buah pir (*pyriform*), bulat (*round*), atau *amorphous*. Kepala juga bisa memiliki vakuola (rongga kecil) yang terlalu banyak (lebih dari dua) atau terlalu besar (lebih dari 20% area kepala. Kepala ganda atau kombinasi cacat lainnya juga termasuk dalam kategori ini.

2. Cacat Leher dan Bagian Tengah

Cacat pada leher atau bagian tengah sperma meliputi penyisipan yang asimetris pada kepala, bentuk leher yang terlalu tebal atau tidak beraturan,

leher yang bengkok, atau terlalu tipis. Berbagai kombinasi cacat ini juga bisa terjadi.

3. Cacat Bagian Ekor (*Principal Piece*)

Pada bagian ekor, sperma bisa memiliki cacat seperti tikungan yang terlalu tajam atau patah, bentuk yang melingkar, lebar yang tidak teratur, atau bagian ekor yang terlalu halus atau kasar. Berbagai kombinasi dari cacat ini juga sering ditemukan.

4. Kelebihan Sitoplasma Residual (ERC)

Sperma yang abnormal sering kali memiliki kelebihan sitoplasma, yaitu bagian sitoplasma yang tidak sempurna terpisah setelah sperma matang. Jika sitoplasma ini menutupi sepertiga atau lebih dari kepala sperma dan sering terkait dengan bagian tengah yang rusak, sperma ini dianggap abnormal. Sitoplasma berlebih ini bukanlah tetesan sitoplasma biasa, tetapi indikasi dari proses pembentukan sperma (spermatogenesis) yang terganggu.

2.3 Digital Image

Citra digital adalah fungsi dua dimensi yang merupakan proyeksi dari suatu keadaan tiga dimensi ke dalam bidang proyeksi dua dimensi (Tyagi, 2018). Citra ini merupakan hasil dari memproyeksikan objek dunia nyata yang tiga dimensi ke dalam sebuah Citra dua dimensi, seperti yang kita lihat di layar komputer atau cetakan foto. Ada beberapa tipe Citra digital, yaitu Citra *binary*, *grayscale*, dan *true-color* (RGB) (Kumar & Verma, 2010). *Binary image* direpresentasikan dengan dua nilai yaitu, 0 dan 1. Citra *grayscale* dikenal sebagai Citra intensitas, atau tingkat keabuan (*gray level*). Terdapat 256 tingkat abu-abu dalam *grayscale image* 8 bit dan intensitas setiap piksel bisa dari 0 hingga 255, dengan 0 untuk hitam dan 255 untuk putih. Sementara itu, Citra *true-color* (RGB) adalah Citra yang setiap pikselnya ditentukan oleh tiga nilai, masing-masing untuk komponen skalar piksel merah, biru, dan hijau (Kumar & Verma, 2010). Komponen warna

ini dikenal sebagai saluran warna (*channel*) atau bidang warna (komponen) (Kumar & Verma, 2010).

Menurut (Tyagi, 2018), Citra digital terbagi ke dalam dua kategori yaitu, Citra *raster* atau bitmap dan Citra vektor. Sebuah Citra bitmap atau *raster* adalah *array* persegi dari nilai-nilai sampel atau piksel. Citra-Citra ini memiliki jumlah piksel yang tetap (Tyagi, 2018). Format-format Citra seperti BMP, GIF, PNG, TIFF, dan JPEG merupakan format Citra bitmap atau *raster*. Sementara itu, Citra vektor disimpan menggunakan representasi matematis berupa garis dan kurva (Tyagi, 2018). Informasi seperti ukuran, warna, tebal garis, dan atribut lainnya disimpan dalam bentuk vektor.

2.4 *Machine Learning*

Machine Learning merupakan salah satu bagian dalam ilmu komputer, dimana komputer mampu mengembangkan model analitik dan meningkatkan kinerjanya secara mandiri, tanpa perlu pemrograman yang eksplisit (Boobier, 2018). Hal ini dicapai dengan menerapkan algoritme yang secara iteratif belajar dari data pelatihan yang khusus untuk masalah tertentu sehingga memungkinkan komputer untuk menemukan pola-pola yang kompleks (Janiesch et al., 2021). Dengan mempelajari pola yang kompleks, algoritme *Machine Learning* dapat membantu komputer menghasilkan keputusan yang dapat diandalkan dan berulang (Janiesch et al., 2021). Oleh karena itu, algoritme *Machine Learning* telah diterapkan dalam banyak bidang, seperti deteksi penipuan, *credit scoring*, *next-best offer analysis*, dan pengenalan ucapan dan Citra, atau pemrosesan bahasa alami (NLP) (Janiesch et al., 2021).

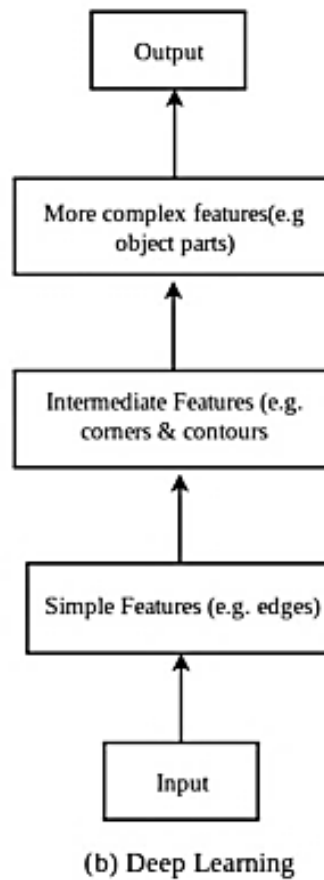
Machine Learning mengandalkan berbagai algoritme untuk menyelesaikan masalah data (Mahesh, 2018). Algoritme ini digunakan untuk memproses sejumlah besar informasi untuk tugas-tugas yang secara alami dapat dilakukan oleh otak manusia, seperti pengenalan Citra dan ucapan, identifikasi pola, atau

optimalisasi strategi (Schuld et al., 2015). Tipe algoritme yang dipilih ditentukan berdasarkan permasalahan yang hendak diselesaikan, besaran variabel yang terlibat, model yang sesuai untuk solusi tersebut, dan faktor-faktor lainnya (Mahesh, 2018) . Dalam *Machine Learning*, terdapat empat tipe pembelajaran yang umum digunakan (Choi et al., 2020). Tipe tersebut diantaranya *supervised learning*, *unsupervised*, *semisupervised learning*, dan *reinforcement learning* (Choi et al., 2020).

2.5 Deep Learning

Deep Learning (DL), sebuah bagian dari *Machine Learning* (ML), terinspirasi oleh pola-pola pemrosesan informasi yang ditemukan dalam otak manusia (Alzubaidi et al., 2021). *Deep Learning* tidak memerlukan aturan yang dirancang oleh manusia untuk beroperasi, sebaliknya, *Deep Learning* menggunakan sejumlah besar data untuk memetakan input yang diberikan ke label-label tertentu (Alzubaidi et al., 2021). Dengan kata lain, *Deep Learning* secara otomatis mempelajari pola dan hubungan yang kompleks dari data yang diberikan untuk menentukan korelasi antara *input* dan *output* yang diinginkan. *Deep Learning* dibuat dengan menggunakan *layer* (jaringan saraf tiruan, atau *Artificial Neural Networks/ANNs*), di mana setiap lapisan memberikan interpretasi yang berbeda terhadap data yang diberikan kepada mereka (Alzubaidi et al., 2021).

Algoritme *Deep Learning* bekerja dengan konsep hirarki (Wani et al., 2020). Pendekatan *Deep Learning* yang menggunakan konsep hierarki dapat dilihat pada Gambar 3.



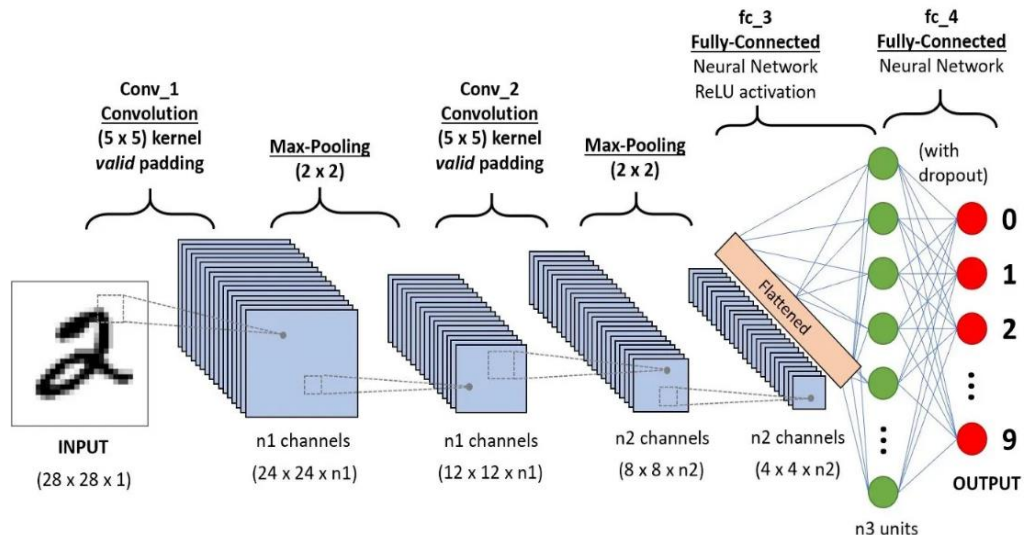
Gambar 3. Pendekatan *Deep Learning* menggunakan hierarki representasi (Wani et al., 2020).

Hal ini merujuk pada arsitektur jaringan saraf tiruan yang memiliki banyak lapisan (disebut juga sebagai "*deep*" dalam *Deep Learning*) di mana setiap lapisan mewakili tingkat abstraksi yang berbeda dari data masukan (Wani et al., 2020). Pada sistem *Deep Learning*, Citra *input* dimasukkan ke dalam jaringan yang terdiri dari beberapa lapisan tersembunyi (Wani et al., 2020). Lapisan-lapisan ini secara bertingkat mengekstrak fitur dari Citra, mulai dari deteksi tepi pada lapisan terendah, hingga pembentukan konsep objek yang lebih abstrak pada lapisan teratas (Wani et al., 2020). Proses ini menciptakan hierarki fitur yang semakin kompleks, di mana setiap lapisan menggunakan *output* dari lapisan sebelumnya untuk membangun representasi yang lebih tinggi dari objek dalam Citra (Wani et al., 2020). Pada akhirnya, lapisan *output* melakukan klasifikasi Citra dan

menghasilkan label kelas berdasarkan representasi fitur yang telah dipelajari oleh jaringan (Wani et al., 2020). Proses ini dapat dilihat sebagai pembelajaran hierarkis karena setiap lapisan dalam jaringan menggunakan keluaran dari lapisan sebelumnya sebagai "bahan bangunan" untuk membangun konsep yang semakin kompleks pada lapisan-lapisan yang lebih tinggi (Wani et al., 2020).

2.6 Convolutional Neural Network (CNN)

CNN merupakan salah satu bagian dari *Deep Learning*. *Convolutional Neural Network* (CNN) terdiri dari serangkaian langkah pembelajaran fitur yang berurutan (Pandya et al., 2021). Setiap langkah memiliki modul konvolusi (*convolution*), pengelompokan (*pooling*), dan normalisasi (*normalization*) (Pandya et al., 2021). *Convolutional Neural Network* (CNN) dapat mengidentifikasi pola-pola yang relevan dalam citra tanpa memperhatikan di mana tepatnya pola tersebut berada di citra atau seberapa besar ukurannya (Pandya et al., 2021). Arsitektur *Convolutional Neural Network* (CNN) sederhana dapat dilihat pada Gambar 4.




Gambar 4. Arsitektur *Convolutional Neural Network* (<https://medium.com>).

2.6.1 *Convolutional Layer*

Dalam *Convolutional Layer* dilakukan operasi konvolusi. Operasi ini melibatkan perkalian elemen *filter* dengan elemen yang sesuai dari *input*, diikuti oleh penjumlahan semua produk tersebut untuk menghasilkan nilai tunggal di lokasi yang sesuai pada *output*. Hasil dari perhitungan operasi matematis ini akan disimpan pada tempat yang sesuai dengan pusat fokus pada lapisan berikutnya (Albawi et al., 2018).

Operasi konvolusi melibatkan *filter* (kernel), *stride* dan *zero padding* (Albawi et al., 2018). Kernel merupakan sekumpulan nilai diskrit atau bilangan bulat (Taye, 2023). Kernel memiliki lebar, tinggi, dan berat yang berguna untuk mengekstraksi karakteristik dari data inputan (Taye, 2023). Kernel memiliki kedalaman yang sama dengan Citra inputan yang memiliki banyak *channel*, seperti RGB (merah, hijau, biru) (Taye, 2023). Beberapa *filter* (kernel) bergerak melintasi data inputan. *Stride*, yang merupakan bilangan bulat positif, menentukan langkah pergeseran *filter* (kernel) (Albawi et al., 2018). Misalnya, *stride* 2 berarti menggeser *filter* dua tempat ke kanan setiap kali dan kemudian menghitung keluarannya. Ukuran keluaran ini akan berkurang pada setiap lapisan konvolusi. Untuk mengatasi hal tersebut, diperlukannya *zero padding*. *Zero padding* menambahkan baris dan kolom nol ke matriks input asli untuk mengontrol ukuran keluaran peta fitur. *Zero padding* bertujuan untuk menyertakan data di tepi matriks inputan (Albawi et al., 2018). Tanpa *zero padding*, ukuran *output* akan berkurang pada setiap lapisan konvolusi, yang berpotensi membatasi kedalaman jaringan karena dimensinya yang semakin kecil secara bertahap (Albawi et al., 2018). *Zero padding* mencegah penurunan ukuran keluaran dan memungkinkan konstruksi jaringan yang lebih dalam dengan kedalaman yang tidak terbatas (Albawi et al., 2018). Operasi konvolusi dapat dilihat pada Gambar 5.



Gambar 5. Operasi konvolusi (Bouguezzi et al., 2021).

2.6.2 Activation Function

Fungsi aktivasi memiliki peranan penting dalam proses pelatihan jaringan saraf (Rasamoelina et al., 2020). Fungsi ini memberikan non-linearitas yang diperlukan pada model agar dapat belajar representasi yang kompleks (Rasamoelina et al., 2020). Tanpa fungsi aktivasi, jaringan saraf akan menjadi serangkaian operasi linear yang tidak mampu menangkap pola-pola non-linear dalam data. Meskipun persamaan linear sederhana dan mudah untuk diselesaikan, namun kompleksitasnya terbatas dan mereka tidak memiliki kemampuan untuk belajar dan mengenali pemetaan yang kompleks dari data (Sharma et al., 2020). Penerapan fungsi aktivasi adalah untuk membuat jaringan menjadi dinamis dan mampu untuk mengekstrak informasi yang kompleks dan rumit dari data serta merepresentasikan pemetaan fungsional non-linear yang berbelit-belit antara masukan dan keluaran (Sharma et al., 2020). Oleh karena itu, dengan menambahkan non-linearitas dengan bantuan fungsi aktivasi non-linear ke dalam jaringan, memungkinkan jaringan untuk menangkap pola yang rumit dan memperluas kemampuan representasi dari data yang diberikan.

Salah satu fungsi aktivasi yang populer digunakan dalam jaringan saraf tiruan (*neural networks*) adalah ReLU (*Rectified Linear Unit*). ReLU merupakan salah satu fungsi aktivasi non-linearitas dengan membiarkan nilai positif melewati tanpa perubahan sementara mengatur nilai negatif menjadi nol (Rasamoelina et al., 2020). Fungsi ini banyak digunakan dalam *deep learning* karena sederhana dan efektif dalam mengatasi masalah hilangnya gradien (Rasamoelina et al., 2020). ReLU dapat didefinisikan pada Persamaan 1.

$$\text{ReLU} = \begin{cases} 0, & \text{jika } x < 0, \\ x, & \text{jika } x \geq 0. \end{cases} \quad (1)$$

Variasi ReLU lainnya adalah *Leaky ReLU*, *Parametric ReLU* (PReLU), dan *Exponential Linear Unit* (ELU), yang masing-masing dengan modifikasi kecil untuk memperkenalkan properti yang berbeda atau mengatasi masalah tertentu (Szandala, 2021).

2.6.3 *Optimizer*

Optimizer adalah algoritme atau metode yang digunakan untuk mengurangi kerugian dengan mengubah properti jaringan saraf, seperti bobot dan tingkat pembelajaran (Chowdhury et al., 2021). Algoritme optimisasi yang tepat memengaruhi kinerja jaringan dan membantu dalam pelatihan yang efektif (Kotta et al., 2021). Berikut ini macam-macam *optimizer* yang populer digunakan adalah SGD, momentum, adagrad, RMSprop, dan adam (Li et al., 2022).

2.6.4 *Hyperparameter*

Penyetelan *hyperparameter* merujuk pada proses mencari konfigurasi *hyperparameter* yang menghasilkan kinerja terbaik. Dalam *Convolutional*

Neural Network (CNN), terdapat beberapa *hyperparameter* yang memengaruhi arsitektur dan kinerja jaringan. Berikut adalah beberapa contoh *hyperparameter* dalam CNN.

a. *Batch size*

Batch merujuk pada sejumlah data yang diproses secara bersamaan dalam satu iterasi saat model pelatihan. *Batch* memungkinkan model membagi *dataset* yang besar menjadi bagian-bagian kecil untuk mengurangi beban memori yang dibutuhkan untuk pelatihan model. Dengan memperhitungkan ukuran *batch* yang tepat, dapat dioptimalkan proses pelatihan model, mengurangi waktu yang dibutuhkan serta meningkatkan efisiensi penggunaan sumber daya komputasi. Terdapat tiga jenis algoritme *gradient descent* berdasarkan ukuran *batch*, yaitu *stochastic gradient descent*, *batch gradient descent*, dan *mini batch gradient descent*.

b. *Epoch*

Epoch adalah satu putaran lengkap melalui seluruh data pelatihan. Selama setiap *epoch*, algoritme menggunakan seluruh *dataset* untuk memperbarui parameter model. Pelatihan biasanya melibatkan beberapa *epoch*, memungkinkan model melihat seluruh *dataset* beberapa kali, yang membantu meningkatkan kinerjanya.

c. *Dropout rate*

Dropout adalah teknik regularisasi yang secara acak "menonaktifkan" sebagian unit dalam jaringan pada setiap iterasi pembelajaran untuk mencegah *overfitting*. Pada setiap *epoch* pelatihan (siklus pelatihan), beberapa neuron secara acak dinonaktifkan (Alzubaidi et al., 2021). *Dropout rate* mengontrol seberapa banyak unit yang dinonaktifkan.

d. *L2 Regularization (Ridge)*

L2 Regularization adalah salah satu jenis regularisasi yang memberikan penalti pada bobot secara proporsional terhadap jumlah kuadrat bobot tersebut. Regularisasi L2 membantu mengurangi bobot yang ekstrem (yang memiliki nilai positif tinggi atau negatif rendah) sehingga bobot-bobot tersebut mendekati 0, tetapi tidak sepenuhnya menjadi 0. Fitur-fitur dengan nilai yang sangat dekat dengan 0 tetap ada dalam model, namun tidak terlalu mempengaruhi prediksi model. *L2 Regularization* didefinisikan pada Persamaan 2.

$$L2 Regularization = (w_1)^2 + (w_2)^2 + (w_3)^2 + \dots (w_n)^2 \quad (2)$$


e. *Learning rate*

Learning rate adalah *hyperparameter* yang menentukan seberapa cepat atau lambat model menyesuaikan bobotnya selama proses pembelajaran. *Learning rate* yang terlalu besar dapat menyebabkan divergensi, sementara yang terlalu kecil dapat menyebabkan konvergensi yang lambat.

2.6.5 *Pooling*

Setelah proses konvolusi, peta fitur (*feature maps*) memiliki sejumlah besar fitur yang rentan menyebabkan masalah *overfitting* (Li et al., 2022). *Pooling Layer*, atau yang biasa dikenali sebagai *down-sampling layer*, digunakan untuk mengurangi dimensi peta fitur sekaligus mempertahankan data yang paling penting (Taye, 2023). Fungsi dari lapisan *pooling* adalah untuk mengecilkan ukuran spasial fitur hasil konvolusi (Bhatt et al., 2021). Dengan mengurangi dimensi, kebutuhan daya komputer untuk memproses data juga berkurang (Bhatt et al., 2021). Hal ini juga membantu dalam mengekstraksi karakteristik utama yang *invariant* terhadap posisi dan

rotasi, sehingga menjaga kepraktisan pelatihan model (Bhatt et al., 2021). *Pooling* mengurangi waktu pelatihan sambil mencegah *overfitting* serta menghilangkan *noise* yang tidak diinginkan (Yang & Li, 2017). Terdapat dua jenis *pooling*, yaitu *maximum pooling* dan *average pooling*. Jenis *pooling* dapat dilihat pada Gambar 6.



Gambar 6. Jenis *pooling* (Taye, 2023).

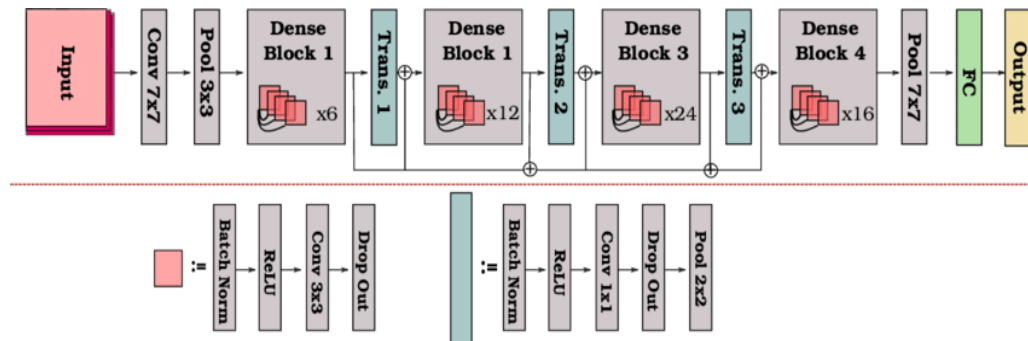
2.6.6 Fully Connected Layer

Fully Connected Layer (Lapisan yang terhubung sepenuhnya) terdapat di lapisan paling bawah jaringan (Bhatt et al., 2021). Lapisan ini bertindak sebagai *classifier* (Yang & Li, 2017). *Fully Connected Layer* menerima masukan dari lapisan *pooling* atau konvolusi terakhir dalam bentuk vektor, yang terbentuk dari peta fitur setelah dilakukan proses *flatten* (Alzubaidi et al., 2021). Keluaran dari lapisan ini merepresentasikan hasil akhir dari CNN (Alzubaidi et al., 2021).

2.7 Densenet

DenseNet adalah salah satu arsitektur jaringan saraf konvolusional (CNN) yang diperkenalkan oleh Gao Huang, Zhuang Liu, dan Kilian Q. Weinberger. Ide dasar dari DenseNet adalah setiap lapisan dalam sebuah jaringan harus saling berhubungan secara langsung satu sama lain, untuk mengoptimalkan aliran

informasi dan meningkatkan pembelajaran fitur (Huang et al., 2017). DenseNet memiliki kemampuan untuk mengatasi masalah *gradient* yang menghilang, memiliki strategi propagasi fitur yang kuat, meminimalkan jumlah parameter yang dilatih, dan mendorong penggunaan ulang fitur (Vulli et al., 2022). Ilustrasi DenseNet dapat dilihat pada Gambar 7.



Gambar 7. DenseNet (Radwan, 2019).

2.7.1 Growth Rate (Laju Pertumbuhan)

DenseNet memperkenalkan konsep laju pertumbuhan, yang menentukan seberapa banyak peta fitur akan dihasilkan oleh setiap lapisan dalam blok. Semakin besar laju pertumbuhan, semakin banyak peta fitur yang akan dihasilkan. Laju pertumbuhan (k) menentukan berapa banyak informasi baru yang ditambahkan setiap lapisan ke representasi data masukan dalam model. Dengan menggabungkan peta fitur dari semua lapisan sebelumnya, *dense block* memungkinkan setiap lapisan mengakses fitur dari semua level sebelumnya. Dalam CNN klasik, setiap lapisan hanya memiliki akses ke karakteristik lapisan sebelumnya (Huang et al., 2017). Arsitektur DenseNet dapat dilihat pada Gambar 8.

Layers	Output Size	DenseNet-121	DenseNet-169	DenseNet-201	DenseNet-264
Convolution	112×112	7×7 conv, stride 2			
Pooling	56×56	3×3 max pool, stride 2			
Dense Block (1)	56×56	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$
Transition Layer (1)	56×56	1×1 conv			
	28×28	2×2 average pool, stride 2			
Dense Block (2)	28×28	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$
Transition Layer (2)	28×28	1×1 conv			
	14×14	2×2 average pool, stride 2			
Dense Block (3)	14×14	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 24$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 32$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 48$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 64$
Transition Layer (3)	14×14	1×1 conv			
	7×7	2×2 average pool, stride 2			
Dense Block (4)	7×7	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 16$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 32$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 32$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 48$
Classification Layer	1×1	7×7 global average pool			
		1000D fully-connected, softmax			

Gambar 8. Arsitektur DenseNet (Huang et al., 2017).

2.7.2 Dense Block

DenseNet terdiri dari beberapa *dense block* yang terdiri dari lapisan-lapisan konvolusi. Di dalam *dense block*, setiap lapisan memiliki koneksi langsung ke setiap lapisan di depannya. Proses di dalam *dense block* dimulai dengan *batch normalization* yang menormalisasi input untuk mengurangi ketergantungan pada distribusi input. Kemudian, fungsi aktivasi ReLU diterapkan untuk memperkenalkan non-linearitas. Kemudian Lapisan konvolusi 3x3 digunakan untuk mengekstraksi fitur dari data yang sudah dinormalisasi dan diaktivasi. Terakhir, *dropout* diterapkan untuk mencegah *overfitting* dengan secara acak mematikan sebagian unit pada lapisan tersebut selama pelatihan. Dalam *dense block*, keluaran dari setiap lapisan digabungkan dengan keluaran dari semua lapisan sebelumnya dan disalurkan sebagai masukan ke lapisan berikutnya (Huang et al., 2017).

2.7.3 *Transition Layers*

DenseNet memiliki lapisan transisi antara *dense block*. *Layer* ini berguna untuk mengurangi dimensi fitur-maps (Huang et al., 2017). Peran lapisan transisi adalah untuk menurunkan sampel peta fitur agar kompatibel dengan lapisan berikutnya. Lapisan transisi biasanya terdiri dari *batch normalization*, konvolusi 1x1 dan lapisan pengurangan dimensi seperti *pooling*.

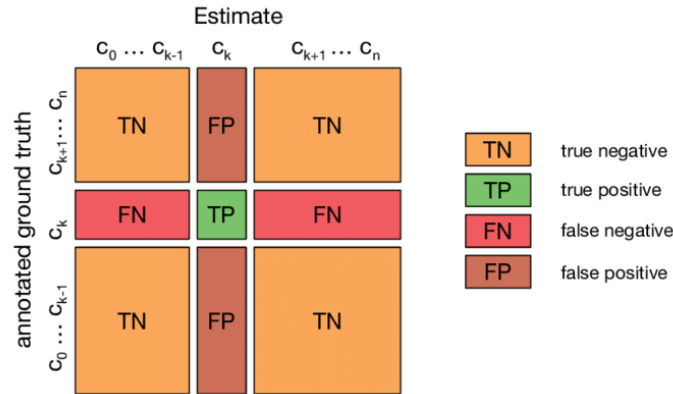
2.7.4 *Classification Layer*

Lapisan klasifikasi pada DenseNet terletak setelah *dense block* dan lapisan transisi. Pada *classification layer* dilakukan klasifikasi pada fitur-fitur yang dihasilkan oleh blok-blok sebelumnya menjadi kelas-kelas tertentu. Pada lapisan ini dilakukan proses *global average pooling* pada peta fitur *output*. Langkah ini menghitung rata-rata dari semua nilai pada peta fitur, menghasilkan satu vektor fitur tunggal. Hasil dari proses *global average pooling* ini kemudian melewati lapisan *fully connected* dengan jumlah neuron kecil (misalnya, 256) dan fungsi aktivasi ReLU. Lapisan ini mengurangi dimensi vektor fitur dan mengekstrak fitur-fitur tingkat yang lebih tinggi. Hasil dari lapisan *fully connected* kemudian melewati fungsi aktivasi *softmax*, yang menghasilkan probabilitas kelas.

2.8 *Confusion Matrix*

Confusion matrix merupakan tabel dua dimensi yang menunjukkan frekuensi hasil untuk dua variabel biner yaitu aktual (baik atau buruk) dan prediksi (baik atau buruk) (Zeng, 2020). *Confusion matrix* digunakan untuk mengevaluasi kinerja

suatu algoritme pembelajaran mesin, terutama pada tugas klasifikasi. *Confusion matrix* dapat dilihat pada Gambar 9.



Gambar 9. *Confusion matrix* (Krüger, 2016).

Keterangan:

- True Positive* (TP): Kasus di mana model memprediksi kelas positif dengan benar, dan prediksi tersebut sesuai dengan kenyataan.
- True Negative* (TN): Kasus di mana model memprediksi kelas negatif dengan benar, dan prediksi tersebut sesuai dengan kenyataan.
- False Positive* (FP): Kasus di mana model memprediksi kelas positif, tetapi kenyataannya kelasnya negatif. FP dikenal sebagai "*Type I error*" atau kesalahan tipe I.
- False Negative* (FN): Kasus di mana model memprediksi kelas negatif, tetapi kenyataannya kelasnya positif. FN dikenal sebagai "*Type II error*" atau kesalahan tipe II.

2.8.1 Accuracy

Akurasi adalah ukuran untuk seberapa banyak prediksi yang benar dibuat oleh model untuk seluruh *dataset* uji. Akurasi adalah *matrix* dasar yang baik untuk mengukur kinerja model (Karimi, 2021). Pada *dataset* yang tidak seimbang, akurasi menjadi metrik yang kurang baik (Karimi, 2021). *True positive* dan *true negative* (pembilang) merupakan jumlah data yang

diklasifikasikan benar dan letaknya pada bagian diagonal utama pada *confusion matrix* sementara penyebutnya merupakan jumlah semua data yang diklasifikasikan oleh model (Grandini et al., 2020). Persamaan akurasi dapat dilihat pada Persamaan 3.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (3)$$

2.8.2 Precision

Precision mengukur seberapa relevan hasil yang diberikan oleh sistem dibandingkan dengan semua hasil yang diambil (Vermeulen, 2018). Sistem dengan presisi tinggi namun *recall* rendah memberikan hasil yang sangat sedikit, namun sebagian besar label prediksinya benar jika dibandingkan dengan label pelatihan (Vermeulen, 2018). Persamaan *precision* dapat dilihat pada Persamaan 4.

$$Precision = \frac{TP}{TP+FP} \quad (4)$$

2.8.3 Recall (sensitivity)

Recall atau *sensitivity* didefinisikan sebagai tingkat positif sebenarnya atau keakuratan positif (Zeng, 2020). *Recall* adalah ukuran seberapa banyak hasil yang benar-benar relevan dikembalikan (Vermeulen, 2018). *Recall* mengukur seberapa banyak kasus positif sebenarnya yang berhasil model prediksi dengan benar. Model dengan *recall* tinggi tetapi presisi rendah mengembalikan banyak hasil, tetapi sebagian besar label prediksinya salah jika dibandingkan dengan label pelatihan (Vermeulen, 2018). Sistem yang ideal memiliki presisi yang tinggi dan *recall* yang tinggi dan memberikan banyak hasil, dengan semua hasil diberi label dengan benar (Vermeulen, 2018). Persamaan *recall* dapat dilihat pada Persamaan 5.

$$Recall = \frac{TP}{TP+FN} \quad (5)$$

2.8.4 *F1-Score*

F1-Score adalah hasil perhitungan rata-rata harmonis antara presisi dan *recall* sehingga memberikan gambaran komprehensif tentang performa model (Karimi, 2021). Nilai *F1-Score* mencapai maksimum ketika presisi sama dengan *recall*. Hal ini menunjukkan bahwa model memiliki keseimbangan yang baik antara kemampuan untuk mengidentifikasi *instance* positif secara benar (presisi) dan kemampuan untuk menemukan semua *instance* positif yang relevan (*recall*). Dengan kata lain, ketika presisi dan *recall* berada pada tingkat yang sama, *F1-Score* memberikan indikasi bahwa model tersebut memiliki kinerja yang komprehensif atau seimbang dalam kedua aspek tersebut. Namun, interpretasi dari *F1-Score* seringkali kurang jelas karena tidak jelas apakah model lebih mengoptimalkan presisi atau *recall* (Karimi, 2021). Persamaan *F1-Score* dapat dilihat pada Persamaan 6.

$$F1 - Score = \frac{2}{\frac{1}{Recall} + \frac{1}{Precision}} = 2 \times \frac{Recall \times Precision}{Recall + Precision} \quad (6)$$

2.9 Augmentasi Data

Salah satu strategi yang efektif untuk mengurangi *overfitting* adalah dengan melatih model pada *dataset* yang beragam dan luas (Ghosh et al., 2020). Salah satu pendekatan umum untuk mengurangi *overfitting* memang melatih model pada sejumlah besar data dengan contoh yang beragam. Augmentasi data adalah teknik yang digunakan untuk meningkatkan ukuran dan keberagaman *dataset* pelatihan secara artifisial dengan menerapkan berbagai transformasi atau modifikasi pada sampel data yang ada (Ghosh et al., 2020). Berikut ini penjelasan mengenai teknik augmentasi data menurut (Shorten & Khosroftaar, 2019) adalah sebagai berikut.

2.9.1 *Geometric transformations*

Geometric transformations adalah transformasi yang mengubah geometri Citra dengan mengubah nilai setiap piksel ke arah yang berbeda (Taylor & Nitschke, 2018). Tujuan dari transformasi geometri adalah untuk memodifikasi geometri Citra sehingga CNN tidak terpengaruh oleh perubahan posisi dan orientasi (Taylor & Nitschke, 2018). Bentuk dasar kelas yang ditunjukkan dalam Citra tetap ada, tetapi nilai piksel diubah ke arah dan posisi yang berbeda (Taylor & Nitschke, 2018).

a. *Flipping*

Pembalikan sumbu horizontal lebih sering diaplikasikan daripada pembalikan sumbu vertikal. Teknik augmentasi ini adalah salah satu yang paling sederhana untuk diterapkan dan telah terbukti bermanfaat pada *dataset* seperti ImageNet dan CIFAR-10 (Shorten & Khoshgoftaar, 2019).

b. *Cropping*

Memotong Citra dapat digunakan sebagai langkah pemrosesan praktis untuk data Citra dengan dimensi tinggi dan lebar yang bervariasi dengan memotong sebuah bagian tengah dari setiap Citra. Selain itu, pemotongan acak dapat memiliki efek yang sangat mirip dengan translasi. Perbedaannya adalah bahwa translasi mempertahankan dimensi spasial Citra, sedangkan pemotongan acak mengurangi ukuran input, seperti 256 x 256 menjadi 224 x 224.

c. *Rotation*

Augmentasi rotasi dilakukan dengan memutar Citra ke kanan atau kiri pada sumbu antara 1° hingga 359° . Rotasi kecil seperti antara 1 hingga 20 atau -1 hingga -20 dapat berguna untuk tugas pengenalan digit seperti MNIST, namun ketika derajat rotasi meningkat, label data tidak lagi dipertahankan setelah transformasi.

d. *Translation*

Menggeser Citra ke kiri, kanan, atas, atau bawah dapat menjadi transformasi yang sangat berguna untuk menghindari bias posisi dalam data. Sebagai contoh, jika semua Citra dalam sebuah *dataset* berada di tengah, yang umum terjadi pada *dataset* pengenalan wajah, maka model akan perlu menguji Citra yang juga berada tepat di tengah. Saat Citra asli digeser ke suatu arah, ruang yang tersisa dapat diisi dengan nilai konstan seperti 0 atau 255, atau diisi dengan *noise* acak atau Gaussian. Teknik ini disebut *padding* dan bertujuan untuk mempertahankan dimensi spasial Citra (tinggi dan lebar) setelah transformasi dilakukan, sehingga Citra tetap berukuran sama meskipun telah digeser.

e. *Shear range*

Shear range pada augmentasi adalah teknik yang digunakan untuk melakukan transformasi *shearing* (pergeseran) pada Citra, yang merupakan jenis distorsi geometris. *Shear* membuat Citra mengalami distorsi sepanjang sumbu tertentu, yang bertujuan untuk menciptakan atau memperbaiki sudut persepsi. Proses ini sering digunakan dalam augmentasi Citra untuk membantu model pembelajaran mesin memahami bagaimana objek dapat terlihat dari berbagai sudut atau sudut pandang.

2.9.2 *Color transformations*

Bias pencahayaan adalah masalah umum dalam pengenalan Citra. Cara untuk mengatasi Citra yang terlalu terang atau gelap adalah dengan menambahkan atau mengurangi nilai piksel secara konstan. Selain itu, manipulasi sederhana lainnya adalah dengan memisahkan matriks warna RGB individu atau membatasi nilai piksel dalam rentang tertentu. Representasi warna dalam Citra digital menawarkan berbagai metode augmentasi yang dapat digunakan. Salah satunya adalah dengan mengubah RGB *matrix* menjadi Citra skala keabuan tunggal, yang memungkinkan pengolahan yang lebih cepat karena ukurannya lebih kecil. Ruang warna

HSV (*Hue*, *Saturation*, dan *Value*) adalah salah satu metode lain untuk menampilkan warna digital selain representasi RGB.

2.9.3 *Kernel Filters*

Teknik yang sangat populer dalam pemrosesan Citra adalah *filter kernel*, yang bekerja dengan menggeser matriks berukuran $n \times n$ melintasi Citra. Teknik ini menghasilkan Citra yang lebih kabur dengan menggunakan *filter Gaussian blur*, atau *filter tepi vertikal (high contrast vertical)* atau horizontal (*high contrast horizontal*) dengan kontras tinggi, yang menghasilkan Citra yang lebih tajam di sepanjang tepinya.

2.10 Statistika Deskriptif

Statistik deskriptif adalah cabang statistik yang mengelola dan menganalisis data atau angka, sehingga dapat menyajikan informasi secara terstruktur, ringkas, dan jelas mengenai suatu fenomena, peristiwa, atau kondisi tertentu, sehingga dapat diperoleh pemahaman atau makna dari data tersebut (Sholikhah, 2016). Adapun menurut (Mishra et al., 2019) terdapat tiga tipe utama statistika deskriptif, yaitu ukuran frekuensi (frekuensi, persen), ukuran kecenderungan sentral (mean, median, dan mode), dan ukuran dispersi atau variasi (varians, Simpangan baku, *standard error*, *quartile*, rentang interkuartil, persentil, rentang, dan koefisien variasi) yang menyediakan ringkasan sederhana mengenai sampel dan pengukurannya. Ukuran frekuensi biasanya digunakan pada data kategorikal sementara untuk pengukuran lainnya digunakan pada data kuantitatif.

2.10.1 Mean

Mean merupakan perhitungan rata-rata nilai dari sebuah kumpulan data (Mishra et al., 2019). *Mean* menghasilkan satu nilai yang unik (*unique value*) sehingga memudahkan dalam perbandingan dengan kumpulan data lainnya (Mishra et al., 2019). Persamaan mean dapat dilihat pada persamaan 7.

$$m = \frac{\sum X}{N} \quad (7)$$

2.10.2 Simpangan Baku dan Varians

Varians dan simpangan baku mengukur bagaimana persebaran nilai data dari nilai rata-rata dari semua data (Kaur et al., 2018). *Dataset* yang memiliki persebaran yang kecil atau nilainya mendekati rata-rata maka nilai varians dan simpangan bakunya kecil. Disisi lain, jika *dataset* memiliki persebaran yang besar atau nilainya jauh dari rata-rata memiliki arti nilai varians dan simpangan baku yang besar. Maka dari itu, jika semua nilai *dataset* sama, maka varians dan simpangan bakunya bernilai 0. Persamaan varians populasi dapat dilihat pada Persamaan 8.

$$\sigma^2 = \frac{\sum (X_i - \mu)^2}{N} \quad (8)$$

Di mana:

σ^2 = Varians data populasi.

X_i = Nilai data ke-i.

μ = Rata-rata data populasi.

N = Jumlah data populasi.

Sementara itu persamaan varians sampel dapat dilihat pada Persamaan 8.

$$s^2 = \frac{\sum (X_i - \bar{x})^2}{n-1} \quad (9)$$

Di mana:

s^2 = Varians data sampel.

X_i = Nilai data ke-i..

\bar{X} = Rata-rata data sampel.

n = Jumlah data sampel.

Sementara itu, simpangan baku diukur dengan akar kuadrat dari varians. Maka dari itu, persamaan simpangan baku populasi dapat dilihat pada Persamaan 10.

$$\sigma = \sqrt{\frac{\sum(X_i - \mu)^2}{N}} \quad (10)$$

Di mana:

σ = Simpangan Baku data populasi.

X_i = Nilai data ke-i.

μ = Rata-rata data populasi.

N = Jumlah data populasi .

Persamaan simpangan baku sampel dapat dilihat pada Persamaan 11.

$$s = \sqrt{\frac{\sum(X_i - \bar{x})^2}{n-1}} \quad (11)$$

Di mana:

S = Simpangan baku data sampel.

X_i = Nilai data ke-i.

\bar{X} = Rata-rata data sampel.

n = Jumlah data sampel.

III. METODOLOGI PENELITIAN

3.1 Tempat dan Waktu Penelitian

Penelitian dilaksanakan di Laboratorium Komputasi Dasar Jurusan Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam (FMIPA) Universitas Lampung. Waktu pelaksanaan penelitian dapat dilihat pada Tabel 2.

Tabel 2. Waktu Penelitian.

Nama Kegiatan	2024						
	April	Mei	Juni	Juli	Agustus	September	Oktober
Akuisi Data	■						
Penyusunan Bab 1-3	■	■					
Praproses Data			■				
Pembagian Data			■				
Pembuatan Model			■	■	■	■	
Pelatihan dan Pengujian				■	■	■	■
Evaluasi Hasil Kinerja Model					■	■	■
Penyusunan Bab 4-5					■	■	■

3.2 Data dan Alat

3.2.1 Data Penelitian

Data yang digunakan dalam penelitian ini, yaitu HusHem dan SCIAN (SCIAN *Gold-standard for Morphological Sperm Analysis*). *Dataset* HusHem merupakan penelitian yang dilakukan oleh (Shaker, 2018) dan diunduh dari <https://paperswithcode.com/dataset/hushem>. Sementara itu *dataset* SCIAN merupakan penelitian yang dilakukan oleh (Chang et al., 2017). *Dataset* yang digunakan terdiri dari dua kumpulan *dataset*, yaitu HuSHem (*Human Sperm Head Morphology*) dan SCIAN (SCIAN *Gold-standard for Morphological Sperm Analysis*). *Dataset* HuSHem terdiri dari empat kelas, yaitu normal, *pyriform*, *tapered*, dan *amorphous*. Citra tersebut memiliki format BMP dengan ukuran 131×131 piksel. *Dataset* HuSHem terdiri dari 216 Citra sel sperma. Sementara itu *dataset* SCIAN berisi 1854 citra kepala sperma yang diklasifikasikan oleh tiga ahli domain referensi asal Chili berdasarkan kriteria Organisasi Kesehatan Dunia (WHO). Citra tersebut memiliki format TIF dengan ukuran 35×35 piksel. *Dataset* ini dikategorikan ke dalam berbagai kelas yaitu normal, berujung (*tapered*), piramida (*pyriform*), kecil (*small*), dan *amorphous*.

3.2.2 Alat

3.2.2.1 Perangkat Keras

Perangkat keras yang digunakan dalam penelitian ini adalah sebagai berikut.

- a. Laptop HP 240 G7 *Notebook*.
- b. *Processor* Intel(R) Core(TM) i5-1035G1 CPU @ 1.00GHz 1.19 GHz.
- c. RAM 8 GB.

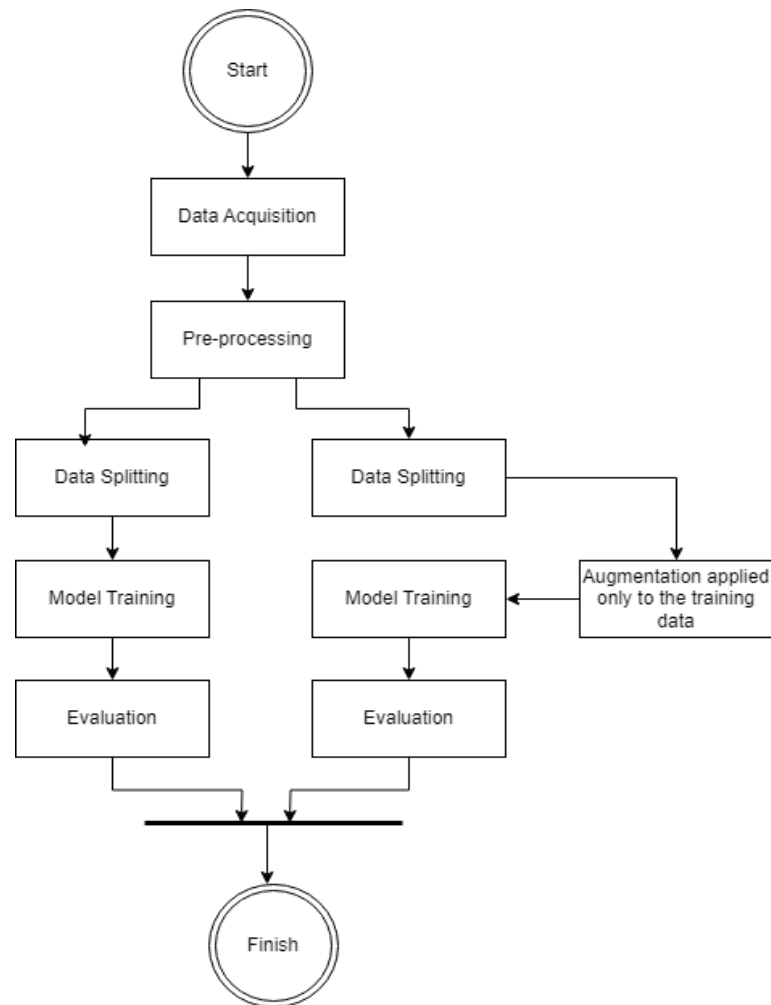
3.2.2.2 Perangkat Lunak

Perangkat lunak yang digunakan dalam penelitian ini adalah sebagai berikut.

- a. Sistem operasi Windows 11 64-bit.
- b. Python 3.10.12.
 - 1) NumPy adalah *library* untuk komputasi numerik di Python.
 - 2) OS adalah modul yang menyediakan berbagai fungsi untuk berinteraksi dengan sistem operasi, seperti membaca dan menulis *file*, memanipulasi jalur *file*, dan menangani direktori.
 - 3) Scikit-learn digunakan untuk evaluasi model dan pra-pemrosesan data.
 - 4) Seaborn dan Matplotlib digunakan untuk visualisasi data dan hasil analisis.
 - 5) OpenCV adalah *library* untuk pengolahan citra dan visi komputer.
 - 6) TensorFlow digunakan untuk membangun dan melatih model *machine learning* dan *deep learning*.
 - 7) TQDM adalah *library* untuk membuat *progress bar* di Python, yang berguna untuk memantau kemajuan dari iterasi yang berjalan lama.
- c. Google Colab *Notebook* sebagai *platform* untuk menulis dan menjalankan kode Python.
- d. Google Drive sebagai penyimpanan *file* dan *folder* dari Google.

3.3 Tahap Penelitian

Penelitian ini memiliki beberapa tahap yang ditunjukkan pada Gambar 10.




Gambar 10. Alur penelitian.


3.3.1 Akuisisi Data

Data yang digunakan dalam penelitian ini adalah HuSHem (*Human Sperm Head Morphology*) dan SCIAN (*SCIAN Gold-standard for Morphological Sperm Analysis*) yang merupakan data sekunder. *Dataset* HuSHem terdiri dari 216 Citra sel sperma dengan masing-masing kelas terdiri dari 54 normal, 53 *tapered*, 57 *pyriform*, dan 52 *amorphous*. *Dataset* SCIAN terdiri dari 1854 Citra sel sperma dengan masing-masing kelas terdiri dari 100

normal, 228 *tapered*, 76 *pyriform*, 72 *small*, dan 656 *amorphous*. Sampel Citra *dataset* dapat dilihat pada Gambar 11 dan Gambar 12.



Gambar 11. *Dataset* HusHem.



Gambar 12. *Dataset* SCIAN.

3.3.2 *Pre-processing*

Pre-processing merupakan serangkaian langkah yang dilakukan pada data *input* sebelum masuk ke dalam jaringan. Tujuannya adalah untuk mempersiapkan data agar lebih sesuai untuk diproses oleh CNN dan meningkatkan kinerja serta keefektifan model. Tahapan *pre-processing* melibatkan persiapan data sebelum model dilatih, yang melibatkan beberapa penyesuaian dan normalisasi pada data. Proses pra-pemrosesan Citra dalam penelitian ini termasuk mengubah ukuran Citra dan normalisasi Citra dengan mengubah nilai piksel dari rentang 0-225 menjadi rentang 0-1. Kemudian teknik augmentasi data juga diterapkan untuk meningkatkan jumlah sampel data pelatihan dengan memanipulasi data asli. Tahap ini melibatkan berbagai *geometric transformations*. Dengan melakukan augmentasi, sistem dapat belajar pola yang lebih umum dan lebih baik

menangkap karakteristik yang penting dari Citra, sehingga meningkatkan kinerja dan generalisasi model pada tugas-tugas pengenalan Citra.

3.3.3 Pembagian Data

Data dibagi menjadi tiga bagian, yaitu data pelatihan (*train*), validasi (*validation*), dan uji (*testing*). Adapun *dataset* tersebut dibagi menjadi tiga skenario, yaitu 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%.

Data pelatihan digunakan untuk melatih model dengan memberikan *input* dan label yang sesuai, di mana model memperbarui bobotnya untuk mengurangi kesalahan prediksi. Data validasi digunakan untuk mengevaluasi kinerja model selama pelatihan dan membantu dalam penyetelan parameter. Hal ini membantu mencegah *overfitting* dan memastikan model yang dilatih dapat secara umum mempelajari pola, dan bukan hanya menghafal data latih. Data uji digunakan untuk menguji kinerja model yang terlatih pada data yang belum pernah dilihat sebelumnya. Data uji membantu mengevaluasi seberapa baik model dapat memprediksi kelas atau label dari data baru yang tidak terlibat dalam pelatihan atau validasi. Dengan pembagian data ini, model CNN dapat belajar pola yang relevan dari data pelatihan, menggeneralisasi dari data validasi, dan diuji pada data uji untuk evaluasi akhir kinerjanya.

3.3.4 Pelatihan Model

Tahap *modelling* DenseNet melibatkan pembangunan arsitektur jaringan saraf tiruan yang terdiri dari beberapa *dense block*, di mana setiap *block* memiliki koneksi yang kuat dengan semua *block* yang berada di atasnya.

Hal ini membuat lapisan-lapisan konvolusi saling terhubung secara langsung, di mana setiap lapisan menerima *input* dari semua lapisan sebelumnya, yang memungkinkan aliran informasi yang kuat dan efisien dalam jaringan. Proses pelatihan model melibatkan penyesuaian parameter model dengan menggunakan algoritme seperti *backpropagation*, di mana bobot dan bias dalam jaringan diperbarui secara iteratif untuk mengurangi kesalahan prediksi antara hasil prediksi dan yang diharapkan, dengan menggunakan data latihan yang diberikan. Adapun *hyperparameter* yang ditetapkan sebelum pelatihan model tersedia pada Tabel 3 dan 4.

Tabel 3. *Hyperparameter Dataset HusHem.*

<i>Hyperparameter</i>	Jenis/Nilai
<i>Learning rate</i>	0.001, 0.0001, 0.00001
<i>Optimizer</i>	Adam
<i>Epoch</i>	100

Tabel 4. *Hyperparameter Dataset SCIAN.*

<i>Hyperparameter</i>	Jenis/Nilai
<i>Learning rate</i>	0.001, 0.0001, 0.00001
<i>Optimizer</i>	Adam
<i>Epoch</i>	100

3.3.5 Evaluasi

Evaluasi model bertujuan untuk mengukur kinerja dan kemampuan model dalam mempelajari representasi fitur dari data. Evaluasi model dilakukan dengan cara menghitung metrik evaluasi seperti akurasi, presisi, *recall*, *F1-score*. Evaluasi ini memberikan wawasan tentang seberapa baik model CNN (*Convolutional Neural Network*) dapat digeneralisasikan ke data baru. Hasil evaluasi ini menilai sejauh mana model mampu menangani berbagai

situasi dan apakah diperlukan penyesuaian tambahan atau *fine-tuning* untuk meningkatkan kinerjanya.

V. SIMPULAN DAN SARAN

5.1 Simpulan

Simpulan yang didapat dari penelitian yang telah dilakukan adalah sebagai berikut.

1. Dalam penelitian ini, model DenseNet169 telah berhasil diimplementasikan untuk tugas klasifikasi Citra sperma (HuSHem dan SCIAN) dengan *dataset* yang masing-masing terdiri dari empat dan lima kelas. Hasil eksperimen menunjukkan bahwa DenseNet169 mampu menghasilkan akurasi yang tinggi dalam tugas pengklasifikasian Citra. Model ini memanfaatkan pendekatan *dense connectivity*, di mana setiap lapisan menerima input dari semua lapisan sebelumnya, sehingga dapat mengurangi *vanishing gradient* dan memaksimalkan efisiensi dalam penggunaan fitur. Pada data HuSHem, skenario pembagian data dengan rasio 80:10:10 mendapatkan akurasi pada data *testing* sebesar 97,73%. Sementara itu, skenario pembagian data dengan rasio 70:25:5 dan 60:20:20 mendapatkan akurasi pada data *testing* masing-masing 97,78% dan 96%. Kemudian pada data SCIAN, pembagian data dengan rasio 80:10:10, 70:25:5, dan 60:20:20 menghasilkan akurasi *testing* masing-masing sebesar 75,15%, 78,79%, dan 73,64%.
2. Berdasarkan hasil evaluasi, model mencapai akurasi pada data *testing* tertinggi pada skenario pembagian data dengan rasio 70:25:5 pada kedua data. Dari hasil tersebut, dapat disimpulkan bahwa skenario pembagian data dengan rasio 70:25:5 memberikan hasil yang paling optimal pada kedua *dataset*, baik HuSHem maupun SCIAN. Pada HuSHem, model

berhasil mencapai akurasi *testing* yang hampir sempurna sebesar 97.78%, sedangkan pada *dataset* SCIAN, skenario yang sama memberikan peningkatan akurasi yang signifikan menjadi 78.79%, dibandingkan dengan rasio pembagian data lainnya. Hal ini menunjukkan bahwa dengan proporsi data *training* (70%) dan validasi yang lebih besar (25%), model mampu generalisasi lebih baik, sehingga memberikan performa yang lebih baik pada data uji. Namun pada data *testing* yang kecil (5%) pada *dataset* yang berjumlah sedikit tidak dapat memberikan hasil yang diandalkan karena ukurannya yang tidak representatif.

3. Model DenseNet169 menunjukkan performa yang baik dalam klasifikasi pada data HuSHem. Hal ini menunjukkan bahwa model mampu menangkap pola-pola yang penting untuk klasifikasi pada *dataset* HuSHem secara konsisten, meskipun pada data proporsi *training* yang berbeda-beda. Perbedaan akurasi yang kecil antara skenario pembagian data menunjukkan bahwa model memiliki kinerja yang stabil, terlepas dari variasi rasio data *training*, validasi, dan *testing*.
4. Secara keseluruhan, model DenseNet169 menunjukkan performa yang cukup baik dalam klasifikasi pada data SCIAN. Hal ini ditunjukkan pada perbedaan akurasi yang signifikan antara skenario pembagian data pada SCIAN. Hal ini mengindikasikan bahwa performa model lebih rentan terhadap perbedaan jumlah data *training* dan validasi. Hal ini bisa terjadi karena data SCIAN memiliki karakteristik yang sulit untuk diklasifikasi atau memiliki citra yang mirip antar kelasnya, sehingga performa model lebih tergantung pada jumlah data yang digunakan dalam pelatihan dan validasi.

5.2 Saran

Rekomendasi untuk penelitian selanjutnya adalah sebagai berikut:

1. Selain DenseNet169, uji coba dengan arsitektur CNN lainnya seperti ResNet atau EfficientNet mungkin memberikan hasil yang lebih baik dalam klasifikasi Citra sperma. Eksperimen ini bisa mengungkap arsitektur mana yang lebih cocok berdasarkan kompleksitas *dataset*.
2. Menggunakan metode pendekatan yang mengatasi ketidakseimbangan data yang lain, seperti *cost-sensitive learning* dengan memberikan bobot yang lebih besar pada kelas minoritas selama pelatihan model.
3. Menggunakan metode penambahan data yang lain seperti teknik pembuatan data sintetis seperti SMOTE (*Synthetic Minority Over-sampling Technique*) atau GANs (*Generative Adversarial Networks*). Teknik ini dapat menghasilkan data baru yang serupa dengan data asli, sehingga meningkatkan jumlah data dan memperkaya variasi Citra dalam *dataset*.

DAFTAR PUSTAKA

- Agarwal, A., Baskaran, S., Parekh, N., Cho, C. L., Henkel, R., Vij, S., Arafa, M., Panner Selvam, M. K., & Shah, R. (2021). Male infertility. In *The Lancet* (Vol. 397, Issue 10271, pp. 319–333). Lancet Publishing Group. [https://doi.org/10.1016/S0140-6736\(20\)32667-2](https://doi.org/10.1016/S0140-6736(20)32667-2)
- Albawi, S., Bayat, O., Al-Azawi, S., & Ucan, O. N. (2018). Social Touch Gesture Recognition Using Convolutional Neural Network. *Computational Intelligence and Neuroscience*, 2018, 1–10. <https://doi.org/10.1155/2018/6973103>
- Alves, M. B. R., Celeghini, E. C. C., & Belleannée, C. (2020). From Sperm Motility to Sperm-Borne microRNA Signatures: New Approaches to Predict Male Fertility Potential. *Frontiers in Cell and Developmental Biology*, 8. <https://doi.org/10.3389/fcell.2020.00791>
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8(1), 53. <https://doi.org/10.1186/s40537-021-00444-8>
- Aronoff, M., & Fudeman, K. (2011). *What is Morphology?*
- Beletti, M. E., Costa, L. da F., & Viana, M. P. (2005). A comparison of morphometric characteristics of sperm from fertile *Bos taurus* and *Bos indicus* bulls in Brazil. *Animal Reproduction Science*, 85(1–2), 105–116. <https://doi.org/10.1016/j.anireprosci.2004.04.019>
- Bhatt, D., Patel, C., Talsania, H., Patel, J., Vaghela, R., Pandya, S., Modi, K., & Ghayvat, H. (2021). CNN Variants for Computer Vision: History, Architecture, Application, Challenges and Future Scope. *Electronics*, 10(20), 2470. <https://doi.org/10.3390/electronics10202470>

- Boobier, T. (2018). Artificial Intelligence. In *Advanced Analytics and AI* (pp. 37–52). Wiley. <https://doi.org/10.1002/9781119390961.ch2>
- Bouguezzi, S., Fredj, H. Ben, Belabed, T., Valderrama, C., Faiedh, H., & Souani, C. (2021). An Efficient FPGA-Based Convolutional Neural Network for Classification: Ad-MobileNet. *Electronics*, *10*(18), 2272. <https://doi.org/10.3390/electronics10182272>
- Breve, F. A. (2022). COVID-19 detection on Chest X-ray images: A comparison of CNN architectures and ensembles. *Expert Systems with Applications*, *204*, 117549. <https://doi.org/10.1016/j.eswa.2022.117549>
- 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.combiomed.2017.03.004>
- Choi, R. Y., Coyner, A. S., Kalpathy-Cramer, J., Chiang, M. F., & Peter Campbell, J. (2020). Introduction to machine learning, neural networks, and deep learning. *Translational Vision Science and Technology*, *9*(2). <https://doi.org/10.1167/tvst.9.2.14>
- Chowdhury, Y. S., Dasgupta, R., & Nanda, S. (2021). Analysis of Various Optimizer on CNN model in the Application of Pneumonia Detection. *2021 3rd International Conference on Signal Processing and Communication (ICSPC)*, 417–421. <https://doi.org/10.1109/ICSPC51351.2021.9451768>
- Eyyubova, G., Serbes, G., & Ilhan, H. O. (2023). The Effect of Differently Optimized Histogram Stretching Techniques on the Classification Performance of Sperm Morphology. *2023 14th International Conference on Electrical and Electronics Engineering (ELECO)*, 1–5. <https://doi.org/10.1109/ELECO60389.2023.10415942>
- Ghosh, A., Sufian, A., Sultana, F., Chakrabarti, A., & De, D. (2020). *Fundamental Concepts of Convolutional Neural Network* (pp. 519–567). https://doi.org/10.1007/978-3-030-32644-9_36
- Grandini, M., Bagli, E., & Visani, G. (2020). *Metrics for Multi-Class Classification: an Overview*.
- Haugen, T. B., Hicks, S. A., Andersen, J. M., Witzak, O., Hammer, H. L., Borgli, R., Halvorsen, P., & Riegler, M. (2019). Using Deep Learning to Predict Motility and Morphology of Human Sperm. *Proceedings of the 10th ACM Multimedia Systems Conference, MMSys 2019*, 261–266. <https://doi.org/10.1145/3304109.3325814>
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely Connected Convolutional Networks. *2017 IEEE Conference on Computer Vision*

- and Pattern Recognition (CVPR)*, 2261–2269. <https://doi.org/10.1109/CVPR.2017.243>
- Ilhan, H. O., Serbes, G., & Aydin, N. (2020). Automated sperm morphology analysis approach using a directional masking technique. *Computers in Biology and Medicine*, 122, 103845. <https://doi.org/10.1016/j.compbimed.2020.103845>
- 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>
- Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 31(3), 685–695. <https://doi.org/10.1007/s12525-021-00475-2>
- Karimi, Z. (2021). *Confusion Matrix*.
- Kaur, P., Stoltzfus, J., & Yellapu, V. (2018). Descriptive statistics. *International Journal of Academic Medicine*, 4(1), 60. https://doi.org/10.4103/IJAM.IJAM_7_18
- Kotta, H., Pardasani, K., Pandya, M., & Ghosh, R. (2021). *Optimization of Loss Functions for Predictive Soil Mapping* (pp. 95–104). https://doi.org/10.1007/978-981-15-3383-9_9
- Krüger, F. (2016). *Activity, Context, and Plan Recognition with Computational Causal Behaviour Models*. University of Rostock.
- Kumar, T., & Verma, K. (2010). A Theory Based on Conversion of RGB image to Gray image. *International Journal of Computer Applications*, 7(2), 5–12. <https://doi.org/10.5120/1140-1493>
- Leslie, S. W., Soon-Sutton, T. L., & Khan, M. A. (2024). *Male Infertility*.
- Li, Z., Liu, F., Yang, W., Peng, S., & Zhou, J. (2022). A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects. *IEEE Transactions on Neural Networks and Learning Systems*, 33(12), 6999–7019. <https://doi.org/10.1109/TNNLS.2021.3084827>
- Mahesh, B. (2018). Machine Learning Algorithms-A Review. *International Journal of Science and Research*. <https://doi.org/10.21275/ART20203995>
- Mashaal, A. A., Eldosoky, M. A. A., Mahdy, L. N., & Ezzat, K. A. (2023). Classification of Human Sperms using ResNet-50 Deep Neural Network. *International Journal of Advanced Computer Science and Applications*, 14(2). <https://doi.org/10.14569/IJACSA.2023.0140282>

- Mishra, P., Pandey, C., Singh, U., Gupta, A., Sahu, C., & Keshri, A. (2019). Descriptive statistics and normality tests for statistical data. *Annals of Cardiac Anaesthesia*, 22(1), 67. https://doi.org/10.4103/aca.ACA_157_18
- Naseem, S., Mahmood, T., Saba, T., Alamri, F. S., Bahaj, S. A. O., Ateeq, H., & Farooq, U. (2023). DeepFert: An Intelligent Fertility Rate Prediction Approach for Men Based on Deep Learning Neural Networks. *IEEE Access*, 11, 75006–75022. <https://doi.org/10.1109/ACCESS.2023.3290554>
- Noha Radwan. (2019). *Leveraging Sparse and Dense Features for Reliable State Estimation in Urban Environments*. <https://doi.org/10.6094/UNIFR/149856>
- Pandya, M., Pillai, A., & Rupani, H. (2021). *Segregating and Recognizing Human Actions from Video Footages Using LRCN Technique* (pp. 3–13). https://doi.org/10.1007/978-981-15-3383-9_1
- Rasamoelina, A. D., Adjailia, F., & Sincak, P. (2020). A Review of Activation Function for Artificial Neural Network. *2020 IEEE 18th World Symposium on Applied Machine Intelligence and Informatics (SAMI)*, 281–286. <https://doi.org/10.1109/SAMI48414.2020.9108717>
- Reddy, A. S. B., & Juliet, D. S. (2019). Transfer Learning with ResNet-50 for Malaria Cell-Image Classification. *2019 International Conference on Communication and Signal Processing (ICCSP)*, 0945–0949. <https://doi.org/10.1109/ICCSP.2019.8697909>
- Schuld, M., Sinayskiy, I., & Petruccione, F. (2015). An introduction to quantum machine learning. *Contemporary Physics*, 56(2), 172–185. <https://doi.org/10.1080/00107514.2014.964942>
- Shaker, F. (2018). *Human Sperm Head Morphology dataset (HuSHeM)*.
- 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.compbiomed.2017.10.009>
- Shaker, F., Monadjemi, S. A., & Naghsh-Nilchi, A. R. (2016). Automatic detection and segmentation of sperm head, acrosome and nucleus in microscopic images of human semen smears. *Computer Methods and Programs in Biomedicine*, 132, 11–20. <https://doi.org/10.1016/j.cmpb.2016.04.026>
- Sharma, S., Sharma, S., & Athaiya, A. (2020). ACTIVATION FUNCTIONS IN NEURAL NETWORKS. *International Journal of Engineering Applied Sciences and Technology*, 04(12), 310–316. <https://doi.org/10.33564/IJEAST.2020.v04i12.054>

- Sholikhah, A. (2016). STATISTIK DESKRIPTIF DALAM PENELITIAN KUALITATIF. *KOMUNIKA: Jurnal Dakwah Dan Komunikasi*, 10(2), 342–362. <https://doi.org/10.24090/komunika.v10i2.953>
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1), 60. <https://doi.org/10.1186/s40537-019-0197-0>
- 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>
- Szandała, T. (2021). *Review and Comparison of Commonly Used Activation Functions for Deep Neural Networks* (pp. 203–224). https://doi.org/10.1007/978-981-15-5495-7_11
- Taye, M. M. (2023). Theoretical Understanding of Convolutional Neural Network: Concepts, Architectures, Applications, Future Directions. *Computation*, 11(3), 52. <https://doi.org/10.3390/computation11030052>
- Taylor, L., & Nitschke, G. (2018). Improving Deep Learning with Generic Data Augmentation. *2018 IEEE Symposium Series on Computational Intelligence (SSCI)*, 1542–1547. <https://doi.org/10.1109/SSCI.2018.8628742>
- Tortumlu, O. L., & Ilhan, H. O. (2020). The Analysis of Mobile Platform based CNN Networks in the Classification of Sperm Morphology. *2020 Medical Technologies Congress (TIPTEKNO)*, 1–4. <https://doi.org/10.1109/TIPTEKNO50054.2020.9299281>
- Tyagi, V. (2018). *Understanding Digital Image Processing*. CRC Press. <https://doi.org/10.1201/9781315123905>
- Vermeulen, A. F. (2018). *Practical Data Science*. Apress. <https://doi.org/10.1007/978-1-4842-3054-1>
- Vulli, A., Srinivasu, P. N., Sashank, M. S. K., Shafi, J., Choi, J., & Ijaz, M. F. (2022). Fine-Tuned DenseNet-169 for Breast Cancer Metastasis Prediction Using FastAI and 1-Cycle Policy. *Sensors*, 22(8), 2988. <https://doi.org/10.3390/s22082988>
- Wani, M. A., Bhat, F. A., Afzal, S., & Khan, A. I. (2020). *Advances in Deep Learning* (Vol. 57). Springer Singapore. <https://doi.org/10.1007/978-981-13-6794-6>
- Wen, L., Li, X., & Gao, L. (2020). A transfer convolutional neural network for fault diagnosis based on ResNet-50. *Neural Computing and Applications*, 32(10), 6111–6124. <https://doi.org/10.1007/s00521-019-04097-w>

- World Health Organization. (2010). *WHO laboratory manual for the Examination and processing of human semen*.
- Yang, J., & Li, J. (2017). Application of deep convolution neural network. *2017 14th International Computer Conference on Wavelet Active Media Technology and Information Processing (ICCWAMTIP)*, 229–232. <https://doi.org/10.1109/ICCWAMTIP.2017.8301485>
- Yüzkat, M., İlhan, H. O., & Aydın, N. (2021). Multi-model CNN fusion for sperm morphology analysis. *Computers in Biology and Medicine*, 137, 104790. <https://doi.org/10.1016/j.combiomed.2021.104790>
- Zeng, G. (2020). On the confusion matrix in credit scoring and its analytical properties. *Communications in Statistics - Theory and Methods*, 49(9), 2080–2093. <https://doi.org/10.1080/03610926.2019.1568485>