

**IMPLEMENTASI MODEL CAPSULE NETWORK  
DENGAN FUNGSI AKTIVASI UNTUK KLASIFIKASI CITRA X-RAY  
DALAM DETEKSI PNEUMONIA**

**Skripsi**

**Oleh**

**ALFREDO RAUL ADAMSYAH  
NPM. 2217031168**



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

**2026**

## **ABSTRACT**

### **IMPLEMENTATION OF THE CAPSULE NETWORK MODEL WITH ACTIVATION FUNCTIONS FOR X-RAY IMAGE CLASSIFICATION IN PNEUMONIA DETECTION**

By

**Alfredo Raul Adamsyah**

Capsule Network (CapsNet) is a development of the Convolutional Neural Network (CNN) that is widely used in image processing, particularly to enhance the model's ability to preserve spatial relationships among object features. This study aims to implement the CapsNet model for the classification of chest X-ray images in pneumonia detection. The dataset used in this study consists of 5,863 chest X-ray images categorized into two classes: normal and pneumonia. The research stages include image preprocessing in the form of image resizing and pixel value normalization, followed by training using the CapsNet architecture for 30 epochs. The activation functions employed include ReLU in the convolutional layer, the squash function in the capsule layer to preserve spatial information in vector form, and the softmax function in the routing by agreement process. The training results show a consistent performance improvement, with training accuracy reaching 98.13% and validation accuracy achieving 96.12% at the 30th epoch. During the testing phase, the model achieved an accuracy of 96.36% with a loss value of 4.33%. Evaluation using the classification report indicates high precision and recall values for both classes, particularly for the pneumonia class, with a precision of 0.98 and a recall of 0.97. The relatively balanced macro average and weighted average F1-score values indicate that the model does not experience significant overfitting and demonstrates good generalization ability despite the imbalanced test data.

**Keywords:** Capsule Network, Fungsi Aktivasi, Klasifikasi Citra X-ray, Pneumonia, Deep Learning.

## ABSTRAK

### IMPLEMENTASI MODEL CAPSULE NETWORK DENGAN FUNGSI AKTIVASI UNTUK KLASIFIKASI CITRA X-RAY DALAM DETEKSI PNEUMONIA

Oleh

**Alfredo Raul Adamsyah**

*Capsule Network* (CapsNet) merupakan pengembangan dari *Convolutional Neural Network* (CNN) yang digunakan dalam pengolahan citra, khususnya untuk meningkatkan kemampuan model dalam mempertahankan hubungan spasial antar fitur objek. Penelitian ini bertujuan untuk mengimplementasikan model CapsNet dalam klasifikasi citra *x-ray* untuk deteksi pneumonia. Dataset yang digunakan terdiri dari 5.863 citra *x-ray* paru-paru yang dikategorikan ke dalam dua kelas, yaitu normal dan pneumonia. Tahapan penelitian meliputi praproses citra berupa penyeragaman ukuran dan normalisasi nilai piksel, kemudian dilakukan pelatihan menggunakan arsitektur CapsNet selama 30 *epoch*. Fungsi aktivasi yang digunakan meliputi ReLU pada lapisan konvolusi, fungsi *squash* pada lapisan kapsul untuk mempertahankan informasi spasial dalam bentuk vektor, serta fungsi *softmax* pada proses *routing by agreement*. Hasil pelatihan menunjukkan peningkatan kinerja yang konsisten, dengan akurasi pelatihan mencapai 98,13% dan akurasi validasi sebesar 96,12% pada *epoch* ke-30. Pada tahap pengujian, model memperoleh akurasi sebesar 96,36% dengan nilai *loss* sebesar 4,33%. Evaluasi menggunakan *classification report* menunjukkan nilai *precision* dan *recall* yang tinggi pada kedua kelas, khususnya pada kelas pneumonia dengan *precision* sebesar 0,98 dan *recall* sebesar 0,97. Nilai *macro average* dan *weighted average F1-score* yang relatif seimbang menunjukkan bahwa model tidak mengalami *overfitting* yang signifikan serta memiliki kemampuan generalisasi yang baik meskipun data uji bersifat tidak seimbang.

**Kata-kata kunci:** *Capsule Network*, Fungsi Aktivasi, Klasifikasi Citra *X-ray*, Pneumonia, *Deep Learning*.

**IMPLEMENTASI MODEL CAPSULE NETWORK  
DENGAN FUNGSI AKTIVASI UNTUK KLASIFIKASI CITRA X-RAY  
DALAM DETEKSI PNEUMONIA**

**ALFREDO RAUL ADAMSYAH**

**Skripsi**

Sebagai Salah Satu Syarat untuk Memperoleh Gelar  
SARJANA MATEMATIKA

Pada

Jurusan Matematika

Fakultas Matematika dan Ilmu Pengetahuan Alam



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

**2026**

Judul Skripsi : **IMPLEMENTASI MODEL CAPSULE NETWORK DENGAN FUNGSI AKTIVASI UNTUK KLASIFIKASI CITRA X-RAY DALAM DETEKSI PNEUMONIA**

Nama Mahasiswa : **Alfredo Raul Adamsyah**


Nomor Pokok Mahasiswa : **2217031168**

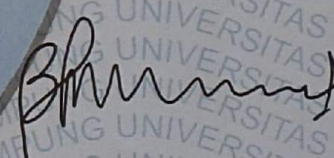
Program Studi : **Matematika**

Fakultas : **Matematika dan Ilmu Pengetahuan Alam**

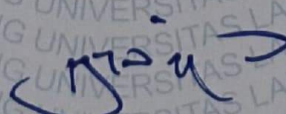


1. Komisi Pembimbing

  
**Widiarti, S.Si., M.Si.**  
NIP 198005022005012003

  
**Dr. Bernadhita H. S. U., S.Si., M.Sc.**  
NIP 199206302023212034

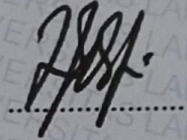
2. Wakil Dekan Bidang Akademik dan Kerjasama  
FMIPA Universitas Lampung

  
**Mulyono, S.Si., M.Si., Ph.D.**  
NIP. 197406112000031002

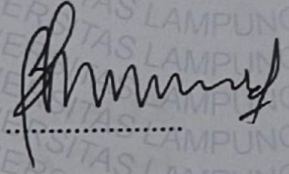
**MENGESAHKAN**

**1. Tim Penguji**


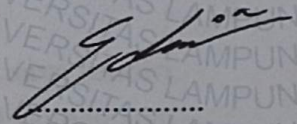
**Ketua : Widiarti, S.Si., M.Si.**



**Sekretaris : Dr. Bernadhita H. S. U., S.Si., M.Sc.**



**Penguji Bukan Pembimbing : Dr. Edwin Russel, S.E., M.Sc.**



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



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

**NIP. 197110012005011002**

**Tanggal Lulus Ujian Skripsi : 28 April 2026**

## PERNYATAAN SKRIPSI MAHASISWA

Yang bertanda tangan di bawah ini:

Nama : **Alfredo Raul Adamsyah**  
Nomor Pokok Mahasiswa : **2217031168**  
Jurusan : **Matematika**  
Judul Skripsi : **IMPLEMENTASI MODEL CAPSULE NETWORK DENGAN FUNGSI AKTIVASI UNTUK KLASIFIKASI CITRA X-RAY DALAM DETEKSI PNEUMONIA**

Dengan ini menyatakan bahwa skripsi ini adalah hasil pekerjaan saya sendiri. Apabila kemudian hari terbukti bahwa skripsi ini merupakan hasil salinan atau dibuat oleh orang lain, maka saya bersedia menerima sanksi sesuai dengan ketentuan akademik yang berlaku.

Bandar Lampung, 28 April 2026

Penulis,



Alfredo Raul Adamsyah

## **RIWAYAT HIDUP**

Penulis memiliki nama lengkap Alfredo Raul Adamsyah lahir pada tanggal 16 Januari 2004 di Kalianda, sebagai anak pertama dari tiga bersaudara dari pasangan Bapak Agus Widodo dan Ibu Maryani.

Penulis memulai perjalanan pendidikannya dari taman kanak-kanak di TK Dharma Wanita Kalianda pada tahun 2009. Pada tahun 2010 penulis memulai melanjutkan pendidikan sekolah dasar di SD Negeri 2 Kalianda. Pada tahun 2016 penulis memulai melanjutkan pendidikan sekolah menengah pertama di SMP Negeri 1 Kalianda. Pada tahun 2019 penulis melanjutkan pendidikan sekolah menengah atas di SMA Negeri 1 Kalianda. Tidak berhenti disitu, penulis melanjutkan pendidikan Strata Satu (S1) di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam (FMIPA) Universitas Lampung pada tahun 2022 melalui jalur SBMPTN.

Selama perkuliahan, penulis pernah menjadi pengurus HIMATIKA Unila dan menjabat sebagai anggota Bidang Minat dan Bakat pada tahun 2023 sampai 2024. Pada tahun 2024 penulis dicalonkan sebagai ketua umum HIMATIKA dan berhasil terpilih sebagai ketua umum HIMATIKA selama 1 minggu, dikarenakan terdapat kendala penulis memilih untuk tidak mempertahankan jabatan ketua umum tersebut. Pada tahun 2024 sampai 2025 penulis menjadi pengurus HIMATIKA Unila menjabat sebagai ketua Bidang Eksternal. Selain itu, pada tahun 2024 sampai 2026 penulis menjadi pengurus IKAHIMATIKA Indonesia Wilayah 2 menjabat sebagai Sub Koordinator Wilayah Lampung. Penulis melaksanakan Kerja Praktik (KP) di Badan Riset dan Inovasi Nasional (BRIN) Bandung pada bulan Januari-Februari 2025. Penulis juga melaksanakan Kuliah Kerja Nyata (KKN) pada bulan Juni-Agustus 2025 di Kelurahan Perumnas Way Kandis, Kecamatan Tanjung Senang, Bandar Lampung.

## KATA INSPIRASI

*“Matematika tidak pernah memiliki solusi bagi mereka yang malas berpikir dan menyerah.”*

*“Hidup ini bukan tentang dimanakah kita akan berjalan, dengan siapakah kita akan berjalan, tetapi mau kemanakah arah langkah kita akan berjalan.”*

*“Aku tidak peduli dengan prestasi apa yang sudah aku dapat tahun sebelumnya, bulan kemarin, atau minggu lalu, yang aku peduli adalah prestasi baru yang harus aku wujudkan.”*  
(Goresan seorang berandal, Mohan Hazian)

*“Jangan bandingkan hidupmu dengan orang lain, mereka juga lagi bingung, cuma beda gaya aja”*

## **PERSEMBAHAN**

Dengan mengucapkan Alhamdulillah dan syukur kepada Allah SWT atas nikmat serta hidayah-Nya sehingga skripsi ini dapat terselesaikan dengan baik dan tepat pada waktunya. Dengan rasa syukur dan bahagia, penulis persembahkan rasa terima kasih kepada:

### **Ayah dan Ibu Tercinta**

Terima kasih kepada orang tua atas segala pengorbanan, motivasi, doa dan ridho serta dukungannya selama ini. Terima kasih telah memberikan pelajaran berharga kepada penulis ini tentang makna perjalanan hidup yang sebenarnya sehingga kelak bisa menjadi orang yang bermanfaat bagi banyak orang.

### **Dosen Pembimbing dan Pembahas**

Terima kasih kepada dosen pembimbing dan pembahas yang sudah sangat membantu, memberikan motivasi, memberikan arahan serta ilmu yang berharga.

### **Sahabat-sahabatku**

Terima kasih kepada semua orang-orang baik yang telah memberikan pengalaman, semangat, motivasinya, serta doa-doanya dan senantiasa memberikan dukungan dalam hal apapun.

### **Almamater Tercinta**

Universitas Lampung

## SANWACANA

Alhamdulillah, puji dan syukur penulis panjatkan kepada Allah SWT atas limpahan rahmat dan karunia-Nya sehingga penulis dapat menyelesaikan skripsi yang berjudul "IMPLEMENTASI MODEL CAPSULE NETWORK DENGAN FUNGSI AKTIVASI UNTUK KLASIFIKASI CITRA X-RAY DALAM DETEKSI PNEUMONIA" dengan baik dan lancar serta tepat pada waktu yang telah ditentukan. Shalawat serta salam semoga senantiasa tercurahkan kepada Nabi Muhammad SAW.

Dalam proses penyusunan skripsi ini, banyak pihak yang telah membantu memberikan bimbingan, dukungan, arahan, motivasi serta saran sehingga skripsi ini dapat terselesaikan. Oleh karena itu, dalam kesempatan ini penulis mengucapkan terimakasih kepada:

1. Ibu Widiarti, S.Si., M.Si. selaku Pembimbing 1 yang telah banyak meluangkan waktunya untuk memberikan arahan, bimbingan, motivasi, saran serta dukungan kepada penulis sehingga dapat menyelesaikan skripsi ini.
2. Ibu Dr. Bernadhita Herindri Samodera Utami, S.Si., M.Sc. selaku Pembimbing II yang telah memberikan arahan, bimbingan dan dukungan kepada penulis sehingga dapat menyelesaikan skripsi ini.
3. Bapak Dr. Edwin Russel, S.E., M.Sc. selaku Penguji yang telah bersedia memberikan kritik dan saran serta evaluasi kepada penulis sehingga dapat menjadi lebih baik lagi.
4. Bapak Dr. Aang Nuryaman, S.Si., M.Si. selaku Ketua Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
5. Bapak Ir. Subian Saidi, S.Si., M.Si. selaku dosen pembimbing akademik.
6. Seluruh dosen, staff dan karyawan Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

7. Seluruh teman Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
8. Rafael, Margo, Fajar, Udin, Joseph, terima kasih banyak atas kebersamaan selama masa perkuliahan, semoga kita dapat bertemu kembali dikemudian hari.

Semoga skripsi ini dapat bermanfaat bagi kita semua. Penulis menyadari bahwa skripsi ini masih jauh dari sempurna, sehingga penulis mengharapkan kritik dan saran yang membangun untuk menjadikan skripsi ini lebih baik lagi.

Bandar Lampung, 28 April 2026  
Penulis,

Alfredo Raul Adamsyah

## DAFTAR ISI

<b>DAFTAR ISI</b> . . . . .	<b>xiii</b>
<b>DAFTAR TABEL</b> . . . . .	<b>xiv</b>
<b>DAFTAR GAMBAR</b> . . . . .	<b>xv</b>
<b>I. PENDAHULUAN</b> . . . . .	<b>1</b>
1.1 Latar Belakang dan Masalah . . . . .	1
1.2 Tujuan Penelitian . . . . .	4
1.3 Manfaat Penelitian . . . . .	4
<b>II. TINJAUAN PUSTAKA</b> . . . . .	<b>5</b>
2.1 Citra <i>X-ray</i> . . . . .	5
2.2 <i>Preprocessing</i> Data . . . . .	5
2.3 <i>Splitting</i> Data . . . . .	6
2.4 CapsNet . . . . .	7
2.5 <i>Convolution Layer</i> . . . . .	8
2.6 Fungsi Aktivasi . . . . .	9
2.7 <i>Primary Capsule Layer</i> . . . . .	10
2.8 <i>Digit Capsule</i> . . . . .	11
2.9 <i>Margin Loss</i> . . . . .	11
2.10 Kompilasi Model . . . . .	12
2.11 Evaluasi Kinerja Model . . . . .	12
2.12 Klasifikasi Gambar . . . . .	15
2.13 Pneumonia . . . . .	15
<b>III.METODE PENELITIAN</b> . . . . .	<b>17</b>
3.1 Waktu dan Tempat Penelitian . . . . .	17
3.2 Data Penelitian . . . . .	17
3.3 Metode Penelitian . . . . .	17

<b>IV. HASIL DAN PEMBAHASAN</b>	<b>21</b>
4.1 Tahap Input Data	21
4.2 Tahap Preprocessing Data	21
4.3 Penentuan <i>Splitting</i> Data	22
4.4 Membangun Arsitektur Model CapsNet	23
4.4.1 <i>Tahap Convolution layer</i>	23
4.4.2 <i>Tahap Primary Capsule Layer</i>	24
4.4.3 <i>Tahap Digit Capsule</i>	24
4.5 Tahap <i>Margin Loss</i>	25
4.6 Pemilihan <i>Optimizer</i> dan <i>Learning Rate</i>	25
4.7 Pelatihan Model	26
4.8 Evaluasi Model	27
4.9 <i>Confusion</i> Matriks	29
<b>V. KESIMPULAN DAN SARAN</b>	<b>32</b>
5.1 Kesimpulan	32
5.2 Saran	32
<b>DAFTAR PUSTAKA</b>	<b>34</b>

## DAFTAR TABEL

1.	<i>Splitting</i> data . . . . .	23
2.	Ringkasan Arsitektur Model CapsNet . . . . .	26
3.	Ringkasan Hasil Pelatihan CapsNet . . . . .	27
4.	Hasil Evaluasi Model . . . . .	28
5.	<i>Confusion</i> Matriks . . . . .	29
6.	<i>Classification Report</i> CapsNet . . . . .	29

## DAFTAR GAMBAR

1.	Arsitektur CapsNet (Hinton <i>et al.</i> , 2017) . . . . .	7
2.	Ilustrasi Proses Pembentukan <i>Feature Map</i> . . . . .	8
3.	<i>Confusion Matrix Binary</i> (Jayakanthan <i>et al.</i> , 2022) . . . . .	13
4.	Citra <i>X-ray</i> . . . . .	16
5.	<i>Flowcart</i> . . . . .	20
6.	<i>Input Citra X-ray</i> . . . . .	21
7.	Grafik Evaluasi Model: (a) Akurasi, (b) <i>loss</i> . . . . .	28

# I. PENDAHULUAN

## 1.1 Latar Belakang dan Masalah

Seiring berkembangnya teknologi kecerdasan buatan *Artificial Intelligence* (AI), terdapat banyak metode *deep learning* yang dapat digunakan untuk memproses data gambar salah satunya adalah *Capsule Network* (CapsNet). CapsNet adalah salah satu model *deep learning* yang dikembangkan untuk mengatasi kelemahan dari *Convolutional Neural Network* (CNN). CNN terkenal dalam mendeteksi objek pada gambar, tetapi memiliki keterbatasan dalam mengenali hubungan antar bagian objek, terutama ketika terjadi rotasi, perubahan ukuran, atau sudut pandang yang berbeda. Ketika suatu objek terlihat dari arah lain, CNN sering kali salah mengenali karena tidak memahami hubungan spasial antar fitur. Hinton *et al.* (2017) memperkenalkan konsep kapsul, yaitu sekumpulan neuron yang tidak hanya menangkap keberadaan suatu fitur, tetapi juga informasi tentang bentuk, arah, dan ukuran (Hinton *et al.*, 2017). Oleh karena itu, CapsNet menggunakan *routing by agreement* untuk menentukan aliran informasi antar kapsul. Prediksi yang saling mendukung koneksinya akan diperkuat, sedangkan prediksi yang tidak sesuai koneksinya akan dilemahkan.

Komponen penting dalam model CapsNet yang sangat mempengaruhi hasil pembelajaran jaringan salah satunya adalah fungsi aktivasi. Fungsi aktivasi berperan dalam memberikan kemampuan non-linear pada model, sehingga jaringan dapat mengenali pola data yang kompleks (Goodfellow *et al.*, 2016). Fungsi aktivasi yang digunakan dalam model CapsNet ini yaitu, ReLU, *squash*, dan *softmax*. Fungsi aktivasi ReLU (*Rectified Linear Unit*), yang bekerja dengan menghilangkan nilai negatif dan mempertahankan nilai positif. Fungsi aktivasi ReLU diterapkan pada lapisan konvolusi awal untuk mempercepat pembelajaran dan mengurangi masalah *vanishing gradient* (Nair dan Hinton, 2010). *Vanishing gradient* adalah masalah dalam

pelatihan jaringan syaraf ketika nilai gradien menjadi sangat kecil saat proses *backpropagation* (menghitung galat), sehingga bobot di layer awal hampir tidak diperbarui (Bengio *et al.*, 1994). Fungsi aktivasi *squash* digunakan pada lapisan kapsul dalam CapsNet untuk menormalkan panjang vektor keluaran sehingga berada pada rentang 0 hingga 1. Panjang vektor ini mewakili probabilitas keberadaan suatu fitur dalam citra, sedangkan arah vektor mempertahankan informasi spasial dari fitur tersebut. Dengan demikian, *squash* memungkinkan CapsNet tidak hanya mengenali apakah fitur ada, tetapi juga bagaimana fitur tersebut terposisi dalam citra (Hinton *et al.*, 2017). Fungsi aktivasi *softmax* adalah fungsi non-linear yang mengubah sekumpulan nilai real menjadi distribusi probabilitas. Setiap nilai *output* berada dalam rentang 0–1, dan jumlah seluruh *output* sama dengan 1 (Goodfellow *et al.*, 2016). Pada CapsNet, *softmax* digunakan untuk menormalisasi koefisien *routing* selama proses *routing by agreement* (Zhao *et al.*, 2019).

Penelitian mengenai CapsNet dalam bidang citra medis terus berkembang. Hinton *et al.* (2017) pertama kali memperkenalkan CapsNet dan menunjukkan bahwa model ini mampu mengatasi keterbatasan CNN dalam mempertahankan informasi spasial antar fitur melalui mekanisme *dynamic routing*. Afshar *et al.* (2020) mengimplementasikan CapsNet pada model COVID-Caps untuk klasifikasi citra *x-ray* dada dan berhasil mencapai akurasi 95,7%, serta terbukti mampu bekerja secara efektif meskipun dataset berukuran kecil. LaLonde & Bagci (2018) mengembangkan SegCaps untuk segmentasi citra medis dan menunjukkan bahwa CapsNet dapat mengurangi kebutuhan data pelatihan hingga 95% tanpa menurunkan performa segmentasi. Secara keseluruhan, penelitian-penelitian tersebut menegaskan bahwa CapsNet memiliki potensi besar dalam klasifikasi dan segmentasi citra medis, terutama pada kondisi dataset terbatas.

Penggunaan sistem berbasis *deep learning* pada citra *x-ray* sudah mulai banyak dipakai karena terbukti bisa membantu tenaga medis (Rajpurkar, *et al.*, 2017). Teknologi ini bisa dijadikan sebagai *decision support system* atau sistem pendukung keputusan yang fungsinya bukan untuk menggantikan dokter, tetapi untuk memberi gambaran awal yang lebih cepat dan akurat. Misalnya, saat dokter menganalisis gambar paru-paru, model *deep learning* bisa memberikan prediksi apakah gambar tersebut normal atau ada indikasi penyakit tertentu. Dengan adanya informasi tambahan

ini, dokter dapat lebih cepat mengambil tindakan, sehingga pasien bisa mendapatkan penanganan yang tepat waktu. Dalam konteks medis, CapsNet juga menjanjikan keunggulan karena dapat mengenali struktur biologis yang bervariasi dari pasien. Salah satu penelitian membuktikan bahwa CapsNet lebih *robust* atau kuat terhadap rotasi dan translasi gambar dibanding CNN yang ditunjukkan oleh Hinton *et al.* (2017) dalam makalah berjudul *Dynamic Routing Between Capsules*, yang menunjukkan bahwa CapsNet mampu mempertahankan performa yang lebih baik pada *dataset* affNIST yang mengandung transformasi rotasi dan translasi dibandingkan CNN konvensional.

Pneumonia merupakan penyakit infeksi paru-paru yang ditandai oleh inflamasi di jaringan kantung udara kecil pada paru-paru. Jaringan tersebut adalah tempat pertukaran gas antara oksigen dan karbon dioksida terjadi, yang dapat terisi cairan, lendir, atau nanah, sehingga menghambat proses pertukaran oksigen (Griadhi, 2016). Penyakit infeksi disebabkan oleh *mikroorganisme patogen* seperti bakteri, virus, dan jamur yang dapat menginfeksi tubuh makhluk hidup serta menimbulkan gangguan kesehatan, dan menjadi salah satu penyebab utama kematian di seluruh dunia, terutama pada anak-anak dan lansia. Menurut Organisasi Kesehatan Dunia (WHO, 2022) pneumonia menyebabkan lebih dari 2,5 juta kematian setiap tahunnya, termasuk lebih dari 700.000 anak di bawah usia lima tahun. Penderita pneumonia biasanya mengalami gejala seperti batuk berdahak, demam, sesak napas, dan nyeri dada, sehingga penanganan yang cepat sangat penting agar kondisi tidak semakin parah (Sherwood, 2016).

Berdasarkan uraian sebelumnya, penulis tertarik untuk mengimplementasikan model CapsNet untuk klasifikasi citra *x-ray*. CapsNet adalah salah satu pengembangan dari model *deep learning* yang dibuat untuk mengatasi kekurangan CNN. CNN hanya fokus mengenali apakah suatu fitur ada atau tidak, sedangkan CapsNet bisa memahami posisi dan arah fitur tersebut di dalam gambar. Misalnya, ada gambar paru-paru yang miring atau sedikit buram, CapsNet tetap mengenalinya dengan baik karena model ini menyimpan informasi spasial antar fitur. CapsNet jadi lebih tahan terhadap perubahan sudut pandang atau rotasi gambar. Sehingga, CapsNet bagus digunakan untuk klasifikasi citra medis seperti *x-ray*, dimana posisi atau bentuk organ bisa sedikit berbeda antara satu gambar dan lainnya (Hinton *et al.*, 2017).

## 1.2 Tujuan Penelitian

Adapun tujuan dari penelitian ini adalah sebagai berikut:

1. membangun model CapsNet untuk mendeteksi pneumonia berbasis citra medis;
2. menganalisis kelebihan dan kekurangan model CapsNet dalam konteks deteksi pneumonia berbasis citra medis;
3. mengetahui tingkat keakuratan penggunaan model CapsNet dalam hal akurasi, *presicion*, *recall*, *F1-score*, dan *confusion* matriks.

## 1.3 Manfaat Penelitian

Adapun manfaat dari penelitian ini adalah sebagai berikut:

1. mengetahui kinerja model CapsNet dalam mendeteksi pneumonia pada citra *x-ray*;
2. menjadi referensi untuk pengembangan metode *deep learning* pada data medis;
3. memberikan solusi kepada tenaga medis tentang potensi AI dalam membantu mendeteksi pneumonia.

## II. TINJAUAN PUSTAKA

### 2.1 Citra *X-ray*

Dataset publik seperti citra *x-ray* yang dikembangkan oleh Wang *et al.* (2017) menyediakan lebih dari 100.000 citra dada dengan label berbagai penyakit, termasuk pneumonia. Dataset seperti ini menjadi landasan penting dalam penelitian medis berbasis komputer. Citra *x-ray* merupakan salah satu teknik medis yang sudah lama dan masih menjadi alat diagnosis utama hingga saat ini. Sejak ditemukan oleh Wilhelm Conrad Rontgen (1895) *x-ray* telah merevolusi dunia kedokteran, karena bisa menunjukkan bagian dalam tubuh tanpa harus melakukan pembedahan atau tindakan langsung ke dalam tubuh (Bushberg *et al.*, 2012). Pada penyakit pneumonia citra *x-ray* mempunyai peran penting, karena bisa memperlihatkan ukuran, bentuk, dan posisi paru-paru.

### 2.2 *Preprocessing Data*

Sebelum data gambar diproses menggunakan model CapsNet, langkah pertama yang dilakukan adalah *preprocessing*. *Preprocessing* data digunakan untuk menghilangkan gangguan dan memperbaiki gambar dengan mengubah ukuran gambar, memperbesar atau memperkecil gambar. Tujuan *preprocessing* data adalah untuk meningkatkan kualitas data sebelum digunakan dalam proses pembelajaran, sehingga model yang dihasilkan menjadi lebih akurat, stabil, dan dapat menghasilkan prediksi dengan baik (Shorten dan Khoshgoftaar, 2019). Teknik *preprocessing* data yang digunakan dalam metode CapsNet ini diantaranya sebagai berikut.

#### 1. *Resize image*

*Resize image* dilakukan untuk menyeragamkan dimensi citra agar semua gambar memiliki ukuran yang sama sebelum masuk ke model. Tujuannya untuk proses komputasi menjadi lebih efisien dan model lebih mudah

mengenali pola karena struktur dimensi citra sudah seragam (Goodfellow *et al.*, 2016).

## 2. *Rescaling*

*Rescaling* merupakan tahap untuk mengubah skala nilai piksel dari 0–255 menjadi 0–1. Tujuannya membantu mempercepat proses pelatihan, memperbaiki stabilitas numerik, dan mencegah nilai besar mendominasi proses pembelajaran (LeCun *et al.*, 1998).

## 3. Augmentasi data

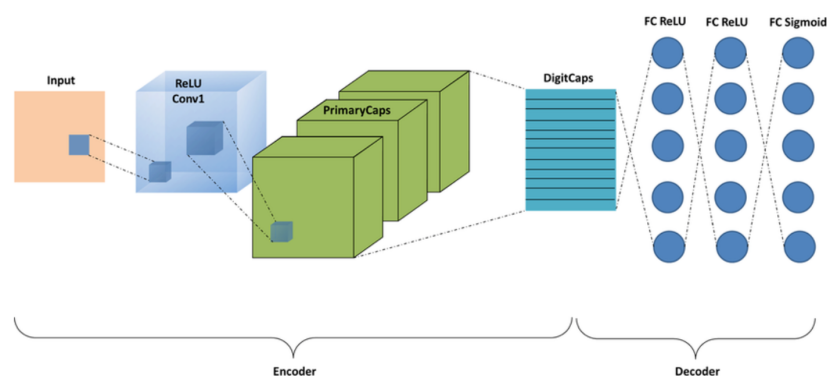
Augmentasi data merupakan teknik memperbanyak variasi gambar tanpa perlu menambah data asli. Seperti memperbesar atau memperkecil, menggeser gambar secara horizontal atau vertikal, dan memiringkan objek. Tujuannya untuk membantu model tidak mudah *overfitting* dan bisa mengenali pola gambar dalam berbagai kondisi (Shorten dan Khoshgoftaar, 2019).

## 2.3 *Splitting Data*

*Splitting* data merupakan proses yang digunakan untuk membagi kumpulan data menjadi tiga bagian yaitu data pelatihan (data *training*), data pengujian (data *testing*), dan data validasi. *Splitting* data bertujuan untuk menghindari terjadinya *overfitting*, yaitu ketika model sangat baik dalam mengenali pola data *training* tetapi kurang baik untuk melakukan prediksi pada data baru. Data *training* digunakan untuk melatih model, data *testing* digunakan untuk memeriksa akurasi model akhir, dan data validasi digunakan untuk memahami kinerja model dengan baik (Joseph, 2022). Menurut Goodfellow *et al.* (2016), pembagian data yang umum digunakan dalam pengembangan model pembelajaran mesin adalah sekitar 70% untuk data pelatihan, 15% untuk data validasi, dan 15% untuk data pengujian. Proporsi ini dianggap cukup seimbang karena memberikan data pelatihan yang cukup besar untuk membangun model, serta menyediakan data validasi dan pengujian yang memadai untuk evaluasi performa model.

## 2.4 CapsNet

CapsNet adalah arsitektur jaringan syaraf tiruan yang menggunakan kapsul atau sekumpulan neuron untuk menangkap tidak hanya keberadaan suatu fitur, tetapi juga informasi tentang bentuk, arah, dan ukuran (Hinton *et al.*, 2017). Tujuannya untuk membantu jaringan dalam mempertahankan hubungan antar hierarki atau tingkatan dalam gambar (Dash *et al.*, 2020). Gambar 1 menyajikan arsitektur CapsNet.



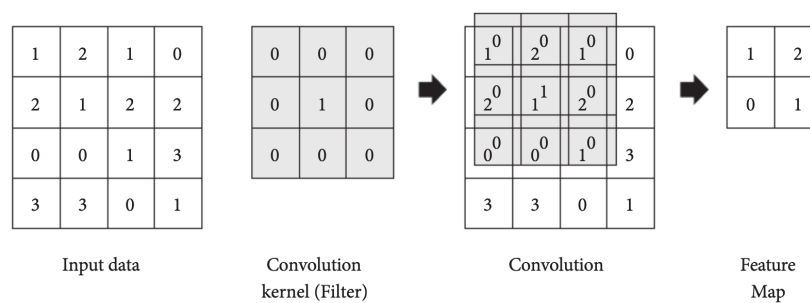
Gambar 1. Arsitektur CapsNet (Hinton *et al.*, 2017)

CapsNet pada Gambar 1 terdiri atas dua bagian utama, yaitu bagian pembelajaran fitur *feature learning* dan bagian klasifikasi berbasis kapsul yang terdapat dalam bagian arsitektur *encoder*. Pada tahap *feature learning*, proses diawali dengan *convolutional layer* yang diikuti oleh fungsi aktivasi ReLU. Proses ini berfungsi untuk mengekstraksi pola-pola dasar dari citra masukan seperti tepi, sudut, dan bentuk objek. Keluaran dari lapisan ini kemudian diteruskan ke *primary capsule*, yang mengubah hasil konvolusi menjadi sekumpulan kapsul. Setiap kapsul terdiri dari beberapa neuron yang membentuk vektor fitur untuk merepresentasikan karakteristik spasial objek. Selanjutnya, proses klasifikasi dilakukan pada *digit capsule* yang bertugas setiap kapsul untuk merepresentasikan satu kelas objek tertentu. Panjang vektor pada *digit capsule* menunjukkan probabilitas keberadaan kelas tersebut pada citra masukan. Meningkatkan akurasi klasifikasi pada CapsNet menerapkan mekanisme *dynamic routing by agreement*, yaitu proses penguatan koneksi antar kapsul yang menghasilkan prediksi yang saling konsisten. CapsNet juga dilengkapi dengan *decoder* yang terdiri dari beberapa *fully connected layer* dengan fungsi aktivasi ReLU dan *sigmoid*. *Decoder* bertugas untuk merekonstruksi kembali citra masukan berdasarkan keluaran

kapsul, yang berfungsi sebagai bentuk regularisasi agar jaringan mampu mempelajari representasi bentuk objek secara lebih baik (Hinton *et al.*, 2017).

## 2.5 Convolution Layer

*Convolution layer* merupakan lapisan awal yang bekerja ketika citra diproses oleh model CapsNet. Lapisan ini berfungsi untuk mengekstraksi ciri-ciri penting dari citra masukan dengan cara mengamati bagian-bagian lokal gambar. Proses ekstraksi dilakukan menggunakan filter atau kernel yang digeser ke seluruh area citra untuk mendeteksi pola visual tertentu, seperti garis, tepi objek, bentuk, dan tekstur (Kalyani *et al.*, 2023). Hasil dari proses ini berupa *feature map*, yaitu representasi yang menunjukkan lokasi keberadaan pola-pola penting pada citra. Menurut Goodfellow *et al.* (2016), *convolution layer* memungkinkan jaringan saraf mengenali pola secara lokal dan efisien karena hanya memproses area kecil citra pada satu waktu, sehingga jumlah parameter yang digunakan menjadi lebih sedikit dibandingkan dengan pemrosesan seluruh piksel secara langsung. Oleh karena itu, *convolution layer* berperan sebagai fondasi utama dalam pembelajaran fitur visual, yang membantu model memahami struktur citra secara otomatis sebelum dilakukan proses klasifikasi. Gambar 2 merupakan ilustrasi proses pembentukan *feature map* pada lapisan konvolusi.



**Gambar 2. Ilustrasi Proses Pembentukan *Feature Map***

Berdasarkan ilustrasi pada Gambar 2 pembentukan *feature map* diawali dengan *input data* yang direpresentasikan sebagai matriks nilai piksel. Sebuah kernel kemudian digeser ke seluruh area citra dan pada setiap posisi dilakukan operasi konvolusi, yaitu perkalian antara nilai piksel dan bobot kernel yang kemudian dijumlahkan untuk menghasilkan satu nilai keluaran. Nilai keluaran

tersebut selanjutnya diproses menggunakan fungsi aktivasi ReLU untuk mempertahankan respons yang relevan. Kumpulan nilai hasil proses ini membentuk feature map, yang merepresentasikan lokasi dan intensitas pola visual tertentu dalam citra masukan (Goodfellow *et al.*, 2016).

## 2.6 Fungsi Aktivasi

Fungsi aktivasi merupakan fungsi yang memetakan nilai hasil konvolusi ke dalam rentang tertentu, yang secara matematis dapat dinyatakan sebagai  $f : \mathbb{R} \rightarrow \mathbb{R}$ . Fungsi aktivasi bersifat non-linear yang memungkinkan jaringan saraf tiruan untuk menyelesaikan permasalahan yang bersifat non-trivial (Alwanda *et al.*, 2020). Fungsi aktivasi yang digunakan dalam metode CapsNet diantaranya sebagai berikut.

### 1. Fungsi ReLu (*Rectified Linear Unit*)

Fungsi ReLu berfungsi untuk menghapus nilai negatif dan mengganti menjadi nilai 0, sedangkan untuk nilai positif dari keluaran neuron atau kapsul dipertahankan atau diteruskan (Nair dan Hinton, 2010). Berikut merupakan persamaan fungsi ReLu yang dapat digunakan.

$$f(x) = \max(0, x), \quad f : \mathbb{R} \rightarrow [0, \infty) \quad (2.1)$$

Sehingga:

$f(x)$  : fungsi aktivasi ReLu dari *input*  $x$ .  
 $x$  : nilai *input* (*output* dari neuron atau kapsul sebelumnya).  
 $\max(0, x)$  : fungsi yang memilih nilai maksimum antara 0 dan  $x$ , jika  $x > 0$ , maka  $f(x) = x$ , dan jika  $x \leq 0$ , maka  $f(x) = 0$ .

### 2. Fungsi *Squash*

Fungsi *squash* adalah fungsi aktivasi non-linear yang digunakan untuk mengatur panjang vektor keluaran kapsul agar tetap dalam rentang 0 sampai 1 tanpa mengubah arah vektor. Panjang vektor didefinisikan sebagai tingkat keyakinan kapsul terhadap keberadaan suatu objek, sehingga vektor berdimensi tinggi dapat diubah menjadi representasi probabilitas. Berikut merupakan persamaan fungsi *squash* yang dapat digunakan.

$$v = \frac{\|s\|^2}{1 + \|s\|^2} \frac{s}{\|s\|} \quad (2.2)$$

Sehingga:

- $s$  : vektor input kapsul.  
 $v$  : vektor *output* kapsul setelah fungsi *squash*.  
 $\|s\|$  : panjang (magnitudo) vektor  $s$ .

### 3. Fungsi *Softmax*

Fungsi aktivasi *softmax* yang digunakan pada arsitektur CapsNet tidak diterapkan pada lapisan keluaran untuk proses klasifikasi. Fungsi aktivasi *softmax* berfungsi untuk menentukan bobot keterhubungan *routing coefficients* (nilai bobot yang dihasilkan) antar kapsul pada proses *dynamic routing*, bukan untuk klasifikasi kelas. CapsNet merepresentasikan keberadaan suatu objek atau kelas melalui panjang vektor kapsul, bukan melalui nilai skalar hasil *softmax*. Panjang vektor tersebut secara langsung menunjukkan probabilitas keberadaan suatu kelas dan proses pelatihannya menggunakan *margin loss* (Hinton *et al.*, 2017).

$$S(y)_i = \frac{e^{y_i}}{\sum_{i=1}^m e^{y_i}} \quad (2.3)$$

Sehingga:

- $S(y)_i$  : probabilitas keluaran untuk kelas ke- $i$ .  
 $y_i$  : nilai logit atau skor masukan untuk kelas ke- $i$ .  
 $e$  : bilangan eksponensial ( $e \approx 2,71828$ ).  
 $m$  : jumlah total kelas yang digunakan proses klasifikasi.  
 $\sum_{i=1}^m$  : faktor normalisasi agar total probabilitas bernilai satu.

## 2.7 Primary Capsule Layer

*Primary capsule layer* merupakan lapisan kapsul pertama pada arsitektur CapsNet yang bertugas mengonversi hasil ekstraksi fitur dari *convolution layer* menjadi kumpulan kapsul berbentuk vektor. Pada CapsNet, *convolution layer* hanya mengekstraksi fitur lokal awal, misalnya pola tepi dan tekstur, sedangkan *primary capsule layer* mengorganisasi fitur-fitur tersebut menjadi representasi yang lebih bermakna dan lebih banyak informasi. Setiap

kapsul terdiri dari sekelompok neuron yang bekerja secara bersamaan untuk merepresentasikan *instantiation parameters* atau kumpulan informasi yang menjelaskan keadaan suatu objek (Hinton *et al.*, 2017). Sehingga, informasi ruang antar bagian objek dapat dipertahankan dan jaringan mampu mengenali objek yang mengalami perubahan posisi, rotasi, bentuk dan ukuran vektor.

## 2.8 *Digit Capsule*

*Digit capsule* merupakan lapisan kapsul tingkat akhir pada CapsNet yang terdiri atas sekumpulan kapsul, dimana setiap kapsul merepresentasikan satu kelas objek. Lapisan ini menerima prediksi pose (vektor) dan parameter instansiasi (nilai numerik yang membentuk pose) dari *Primary capsule layer* melalui proses *dynamic routing* untuk membentuk vektor keluaran berdimensi tinggi. Panjang vektor pada *digit capsule* mencerminkan probabilitas keberadaan objek pada kelas tertentu, sehingga model dapat melakukan klasifikasi berdasarkan tingkat keyakinan kapsul terhadap kelas yang diwakilinya (Hinton *et al.*, 2017). Pada *digit capsule* hasil pengolahan fitur dalam CapsNet tidak hanya bergantung pada kehadiran fitur, tetapi juga pada kesesuaian antar fitur dalam menyusun objek.

## 2.9 *Margin Loss*

Fungsi kerugian (*loss function*) yang digunakan dalam model CapsNet adalah *Margin loss*, yang berfungsi untuk mengukur kesalahan prediksi berdasarkan panjang vektor kapsul pada setiap kelas. Panjang vektor (*magnitudo*) menunjukkan probabilitas keberadaan suatu kelas, vektor yang panjang menandakan kelas terdeteksi, sedangkan vektor yang pendek menunjukkan kelas tidak terdeteksi. *Margin loss* bekerja dengan membandingkan panjang vektor dengan nilai batas tertentu untuk setiap kelas, sehingga mendorong representasi kelas yang benar menjadi lebih dominan dibandingkan kelas lain (Hinton *et al.*, 2017). Menurut LaLonde & Bagci, menegaskan *margin loss* juga berkontribusi dalam meningkatkan kemampuan generalisasi model terhadap variasi rotasi dan deformasi citra karena panjang vektor kapsul tetap merepresentasikan keberadaan objek secara konsisten (LaLonde & Bagci, 2018).

## 2.10 Kompilasi Model

Kompilasi model merupakan tahap pengaturan bagaimana model akan belajar sebelum proses pelatihan dimulai, salah satu kompilasi model yang digunakan adalah *optimizer adam (Adaptive Moment Estimation)*. *Optimizer adam* merupakan algoritma optimisasi yang banyak digunakan dalam *deep learning* karena mampu menyesuaikan laju pembelajaran secara adaptif berdasarkan rata-rata momentum dan varians gradien, sehingga dapat mempercepat proses konvergensi. Pemilihan konfigurasi *loss function* dan *optimizer* pada tahap kompilasi secara langsung menentukan bagaimana model mempelajari pola dari data, meminimalkan kesalahan prediksi, serta mencapai konvergensi pelatihan yang stabil dan efisien (Kingma & Ba, 2014).

## 2.11 Evaluasi Kinerja Model

Evaluasi kinerja model dilakukan untuk mengetahui seberapa baik model yang sudah dilatih dalam mengenali data baru (Maulana, 2023). Salah satu cara yang sering digunakan dengan *confusion matrix*, yaitu tabel yang menunjukkan jumlah prediksi yang benar dan salah pada data uji. Menurut Fawcett *confusion matrix* membuat performa algoritma klasifikasi dengan membandingkan hasil prediksi terhadap kelas sebenarnya (Fawcett, 2006). *Confusion matrix* ada dua jenis *multiclass* (banyak kelas) dan *binary classification* (dua kelas) (Markoulidakis *et al.*, 2021). Pada data ini menggunakan *binary classification* dengan dua kelas pneumonia dan normal. *Confusion matrix* untuk *binary classification* merupakan tabel berdimensi  $2 \times 2$  yang terdiri dari empat kombinasi berbeda antara nilai prediksi dan nilai aktual. Ada empat istilah yang merupakan representasi hasil proses *binary classification* pada *confusion matrix* yaitu *True Positif (TP)*, *True Negatif (TN)*, *False Positif (FP)*, dan *False Negatif (FN)*. Berikut ini merupakan gambar ilustrasi *confusion matrix binary classification*.

		Actual Values	
		Positive (1)	Negative (0)
Predicted Values	Positive (1)	TP	FP
	Negative (0)	FN	TN

**Gambar 3. Confusion Matrix Binary (Jayakanthan et al., 2022)**

Beberapa metrik yang dapat digunakan pada *binary classification*, diantaranya yaitu *accuracy*, *precision*, *recall*, dan *F1-score*. Berikut ini diuraikan definisi dari metrik kinerja untuk *binary classification*.

#### 1. Accuracy

*Accuracy* adalah proporsi dari total jumlah prediksi yang benar dari hasil klasifikasi (Markoulidakis et al., 2021). Adapun rumus matematis dari *accuracy* adalah sebagai berikut.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (2.4)$$

Sehingga:

- $TP$  : True Positif.
- $TN$  : True Negatif.
- $FP$  : False Positif.
- $FN$  : False Negatif.

#### 2. Precision

*Precision* atau nilai prediksi positif adalah proporsi dari prediksi positif yang tepat dari semua data yang diprediksi positif dari hasil klasifikasi (Mughal et al., 2022). Adapun rumus matematis dari *precision* adalah sebagai berikut.

$$\text{Precision} = \frac{TP}{TP + FP} \times 100\% \quad (2.5)$$

Sehingga:

$TP$  : *True Positif*.  
 $FP$  : *False Positif*.

### 3. *Recall*

*Recall* atau sensitivitas adalah proporsi dari semua data aktual positif yang diprediksi dengan benar sebagai positif dari hasil klasifikasi (Mughal *et al.*, 2022). Adapun rumus matematis dari *recall* adalah sebagai berikut.

$$\text{Recall} = \frac{TP}{TP + FN} \times 100\% \quad (2.6)$$

Sehingga:

$TP$  : *True Positif*.  
 $FN$  : *False Negatif*.

### 4. *F1-score*

*F1-score* adalah rata-rata menyeimbangkan antara *presicion* dan *recall* untuk model klasifikasi tertentu (Mughal *et al.*, 2022). Adapun rumus matematis dari *F1-score* adalah sebagai berikut.

$$\text{F1-Score} = \frac{2 \times \text{Recall} \times \text{Precision}}{\text{Recall} + \text{Precision}} \times 100\% \quad (2.7)$$

Sehingga:


*Precision* : Tingkat ketepatan prediksi positif.  
*Recall* : Tingkat keberhasilan model dalam menemukan seluruh data positif.

## 2.12 Klasifikasi Gambar

Klasifikasi gambar adalah proses mengelompokkan citra digital ke dalam kategori tertentu berdasarkan pola atau ciri yang ada di gambar (Goodfellow *et al.*, 2016). Tujuannya bukan hanya untuk membedakan objek, tetapi juga agar komputer bisa memahami isi data dan menafsirkan informasi secara lebih cerdas. Klasifikasi gambar dalam CapsNet dilakukan dengan cara yang lebih canggih dibanding CNN biasa. CapsNet tidak hanya mendeteksi fitur, tetapi juga memahami hubungan antar bagian objek serta posisi dan orientasinya (Hinton *et al.*, 2017). Fitur gambar pertama-tama diambil melalui *convolutional layer*, lalu dibentuk menjadi vektor di *primary capsule layer*. Vektor ini diproses dengan fungsi *squash* untuk menyesuaikan panjangnya atau magnitudo, yang menunjukkan seberapa yakin kapsul bahwa objek ada. Kapsul di lapisan bawah mengirim informasi ke kapsul lapisan atas yang relevan, dan kapsul dengan magnitudo terbesar menentukan kelas prediksi akhir melalui *dynamic routing*. CapsNet mampu melakukan klasifikasi gambar, dengan cara ini lebih akurat dan tangguh terhadap rotasi, pergeseran, atau perubahan ukuran objek.

## 2.13 Pneumonia

Pneumonia merupakan salah satu penyakit infeksi paru-paru yang masih menjadi masalah kesehatan serius di seluruh dunia. Dampak penyakit pneumonia cukup beragam, mulai dari paparan asap rokok, polusi udara, kurang asupan gizi, hingga keterlambatan dalam memperoleh akses layanan kesehatan. Deteksi dini menjadi sangat penting, karena gejala pneumonia seperti batuk, demam, dan sesak napas sering kali mirip dengan infeksi pernapasan lainnya. Perkembangan teknologi kecerdasan buatan saat ini sangat membantu tenaga medis dalam proses identifikasi pneumonia. AI dapat menganalisis citra radiologi salah satunya *x-ray*, untuk mendeteksi tanda-tanda pneumonia dengan lebih cepat dan akurat dibanding pemeriksaan manual (Rajpurkar *et al.*, 2017). Menggunakan algoritma *deep learning*, model AI bisa mengenali pola-pola halus dalam gambar yang mungkin bisa membantu tenaga medis tetapi bukan untuk menggantikan tenaga medis. Gambar 4 menampilkan ciri-ciri citra *x-ray* normal dan pneumonia sebagai berikut.



**Gambar 4. Citra *X-ray***

Ciri-ciri pada *x-ray* normal ditandai dengan paru-paru yang tampak jernih tanpa area bercak putih, tulang rusuk terlihat jelas, dan ruang paru simetris. Sedangkan *x-ray* pada pasien pneumonia menunjukkan infiltrasi atau bercak putih di paru-paru akibat akumulasi cairan, kadang disertai konsolidasi atau daerah yang tampak padat, serta bisa tampak pergeseran pola ventilasi paru (Finaldi, 2024).

### **III. METODE PENELITIAN**

#### **3.1 Waktu dan Tempat Penelitian**

Penelitian ini dilakukan pada semester ganjil tahun akademik 2025/2026 dan bertempat di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung yang beralamatkan di Jalan Prof. Dr. Ir. Soemantri Brojonegoro, Gedong Meneng, Kecamatan Rajabasa, Kota Bandar Lampung, Lampung.

#### **3.2 Data Penelitian**

Data yang digunakan dalam penelitian ini adalah data citra medis yang berasal dari platform Kaggle dengan judul *Chest X-Ray Images Pneumonia* yang dipublikasikan oleh Paul Mooney (2018). Dataset ini merupakan kumpulan citra *x-ray* dada pasien yang digunakan untuk mendeteksi kondisi normal dan pneumonia. Total jumlah kumpulan data ini yaitu 5.863 gambar dengan kelas normal terdiri dari 1.583 gambar, dan kelas pneumonia terdiri dari 4.273 gambar.

#### **3.3 Metode Penelitian**

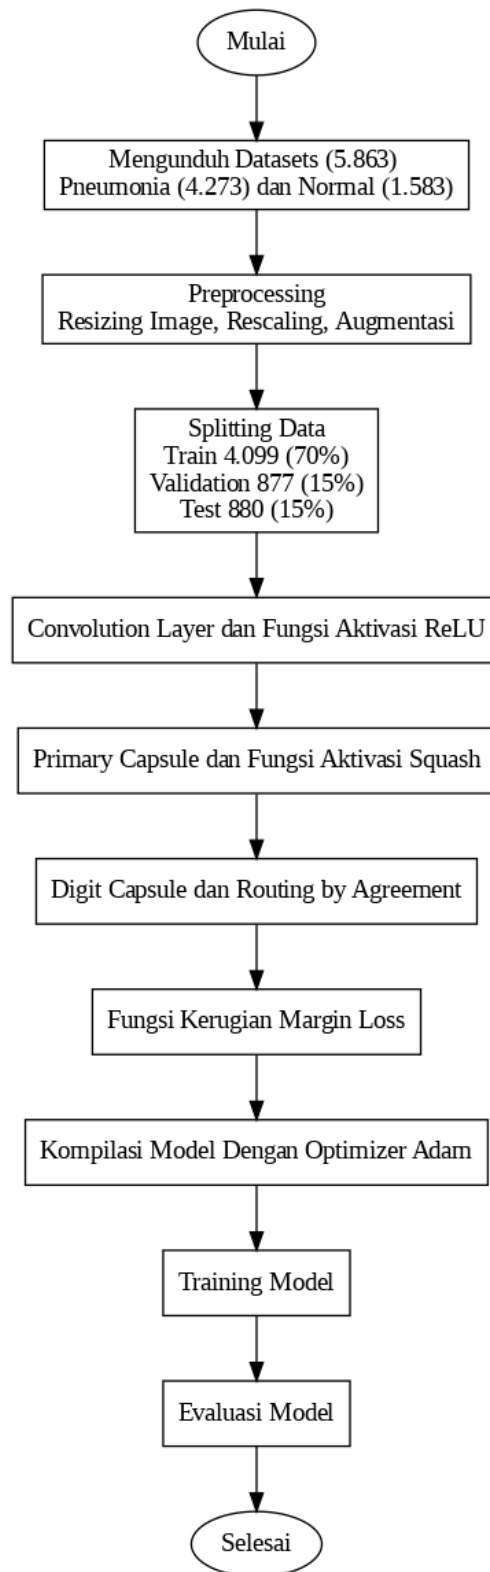
Penelitian ini menggunakan model CapsNet untuk melakukan klasifikasi pneumonia berdasarkan citra *x-ray* dada yang diperoleh dari dataset Kaggle. Aplikasi yang digunakan dalam penelitian ini adalah *google colab* dan bahasa pemrograman python. Langkah-langkah yang dilakukan pada penelitian ini sebagai berikut.

1. Melakukan studi literatur tentang metode klasifikasi CapsNet.

2. Mengunduh dataset citra *x-ray* dada dari *kaggle* yang berisi dua kelas yaitu, pneumonia dan normal untuk digunakan sebagai data latih, validasi, dan uji.
3. Sebelum masuk ke dalam komponen CapsNet, dilakukan *preprocessing*. Proses ini mencakup *resizing image* mengubah ukuran citra menjadi  $128 \times 128$  piksel agar ukuran data seragam, selanjutnya melakukan *rescaling* dengan mengubah nilai piksel dari 0–255 menjadi 0–1 agar perhitungan lebih stabil. Selain itu, dilakukan augmentasi data seperti rotasi, perbesaran (*zoom*), dan pergeseran (*translation*) untuk meningkatkan variasi citra tanpa menambah jumlah data secara nyata. Perbesaran bertujuan untuk memperbesar objek dalam citra sehingga model dapat mempelajari fitur atau detail yang lebih spesifik. Sementara itu, pergeseran digunakan untuk mengubah posisi objek dalam citra agar model tidak bergantung pada letak tertentu.
4. Data citra *x-ray* dibagi menjadi tiga bagian, yaitu *training* 4.099 (70%), *validation* 877 (15%), dan *testing* 880 (15%). Kelas pada dataset terlabelkan pneumonia dan normal. Pembagian komposisi ini bertujuan untuk menyeimbangkan proses pelatihan, evaluasi, dan pengujian model. Data *training* digunakan untuk melatih model, data *validation* untuk mengevaluasi dan mencegah *overfitting*, serta data *testing* untuk mengukur performa akhir model terhadap data baru.
5. *Convolution layer* digunakan sebagai tahap awal dalam arsitektur CapsNet untuk mengekstraksi fitur-fitur penting dari citra *x-ray*. Citra diseragamkan dengan ukuran  $128 \times 128$  piksel dengan satu kanal (*grayscale*). Proses ekstraksi fitur ini dilakukan menggunakan lapisan Conv2D dengan jumlah filter sebanyak 256, ukuran kernel  $9 \times 9$ , dan nilai *stride* sebesar 4, serta menggunakan fungsi aktivasi ReLU. Lapisan ini berfungsi untuk menangkap pola-pola dasar pada citra, seperti tepi, tekstur, dan struktur lokal yang relevan untuk membedakan citra normal dan pneumonia.
6. Setelah proses *convolution layer*, keluaran diubah menjadi kumpulan vektor untuk diproses oleh *primary capsule layer*. Pada tahap ini, setiap 8 nilai hasil *convolution layer* dikelompokkan menjadi satu, menggunakan 256 filter dengan membuat 32 kapsul masing-masing berdimensi 8. Menggunakan kernel *size*  $9 \times 9$  piksel untuk melihat lebih besar bagian pada gambar dan fokus ke bentuk objek yang lebih lengkap pada gambar. Menggunakan *stride* 2 sehingga filter bergeser dua piksel pada arah

horizontal maupun vertikal. Selanjutnya menggunakan fungsi *squash* untuk menormalkan panjang vektor ke rentang 0–1, dengan panjang vektor menunjukkan tingkat kepastian keberadaan fitur.

7. *Digit capsule* mengubah keluaran dari *primary capsule* menjadi kapsul keluaran per kelas melalui mekanisme *routing by agreement*, yaitu proses yang menguatkan kontribusi kapsul *input* yang memiliki prediksi konsisten dan melemahkan kapsul yang tidak sejalan.
8. Melakukan fungsi kerugian *margin loss* untuk mengatur panjang vektor kapsul, yaitu dengan memperbesar panjang vektor pada kelas yang benar dan mengecilkan panjang vektor pada kelas yang salah sehingga model dapat belajar fitur dengan lebih akurat dan menekan kesalahan klasifikasi. Mengurangi kesalahan prediksi, parameter seperti *learning rate*, *epoch*, dan *batch size* disesuaikan agar model mencapai akurasi optimal dalam mengenali citra pneumonia.
9. Setelah arsitektur CapsNet dibangun, model dikompilasi menggunakan *optimizer* Adam dengan *learning rate* 0,0001 untuk memperbarui bobot jaringan secara adaptif, sehingga mengubah kecepatan belajar tiap bobot secara otomatis.
10. Selanjutnya melakukan pelatihan model untuk mengenali pola pada data dengan menyesuaikan bobot jaringan secara bertahap. Pelatihan dilakukan selama 30 *epoch*, artinya seluruh dataset dilalui sebanyak 30 kali, dengan *batch size* 32, sehingga model memperbarui bobotnya setiap 32 sampel. Selama pelatihan, nilai *loss* dan akurasi pada data pelatihan maupun validasi dicatat menggunakan objek histori untuk memungkinkan pemantauan proses pelatihan dengan merekam nilai *loss* dan akurasi pada data pelatihan maupun validasi.
11. Setelah dilakukan pelatihan model dilakukan evaluasi untuk mengukur kemampuan generalisasi CapsNet terhadap data uji.



**Gambar 5. Flowcart**

## V. KESIMPULAN DAN SARAN

### 5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan dalam implementasi model CapsNet dengan fungsi aktivasi untuk klasifikasi citra *x-ray* dalam deteksi pneumonia diperoleh kesimpulan sebagai berikut:

1. Arsitektur CapsNet yang digunakan terdiri dari *convolution layer*, *primary capsule layer*, dan *digit capsule layer* dengan mekanisme *dynamic routing*, serta didukung fungsi aktivasi *squash* dan *margin loss*, sehingga mampu mengekstraksi fitur dan mengklasifikasikan citra ke dalam dua kelas, yaitu normal dan pneumonia.
2. Model CapsNet memiliki keunggulan dalam mempertahankan informasi spasial dan hubungan antar fitur, sehingga mampu mengenali pola citra dengan baik dan membedakan kelas secara efektif. Namun demikian, model CapsNet ini memiliki keterbatasan pada kompleksitas arsitektur, kebutuhan komputasi yang tinggi, serta waktu pelatihan yang relatif lebih lama.
3. Model berhasil mencapai akurasi sebesar 98,13% pada data pelatihan dan 96,36% pada data pengujian, dengan perbedaan yang kecil sehingga menunjukkan tidak terjadi *overfitting* dan memiliki kemampuan generalisasi yang baik. Evaluasi menggunakan *confusion matrix*, *precision*, *recall*, dan *F1-score* menunjukkan performa yang tinggi dan seimbang pada kedua kelas, dengan 848 prediksi benar dari 880 data uji.

### 5.2 Saran

Berdasarkan keseluruhan hasil penelitian dan kesimpulan yang telah diperoleh, maka penulis memberikan beberapa saran yang diharapkan dapat menjadi acuan dalam pengembangan penelitian lebih lanjut sebagai berikut:

1. Meningkatkan ukuran dataset agar model dapat mengenali variasi citra yang lebih luas, sehingga kemampuan generalisasi menjadi lebih optimal.
2. Melakukan pengujian dengan resolusi citra yang lebih tinggi (misalnya  $256 \times 256$ ) untuk melihat pengaruh ukuran citra terhadap akurasi.
3. Implementasi augmentasi data tambahan atau penggunaan CapsNet dengan arsitektur lebih dalam dapat dieksplorasi untuk meningkatkan akurasi dan ketahanan model terhadap variasi citra.
4. Evaluasi dengan metrik lain seperti *precision*, *recall*, dan *F1-score* disarankan agar analisis performa model lebih komprehensif, terutama untuk klasifikasi medis yang membutuhkan tingkat keakuratan tinggi.

## DAFTAR PUSTAKA

- Afshar, P., Heidarian, S., Naderkhani, F., Oikonomou, A., Plataniotis, K. N., & Mohammadi, A. (2020). COVID-CAPS: A capsule network-based framework for identification of COVID-19 cases from X-ray images. *IEEE Transactions on Medical Imaging*, 39(11), 3497–3507.
- Alwanda, M. R., Ramadhan, R. P. K., & Alamsyah, D. (2020). Implementasi metode convolutional neural network menggunakan arsitektur LeNet-5 untuk pengenalan doodle. *Jurnal Algoritme*, 1(1), 45–56.
- Bengio, Y., Simard, P., & Frasconi, P. (1994). Learning long-term dependencies with gradient descent is difficult. *IEEE Transactions on Neural Networks*, 5(2), 157–166.
- Bushberg, J. T., Seibert, J. A., Leidholdt, E. M., & Boone, J. M. (2012). *The essential physics of medical imaging* (3rd ed.). Lippincott Williams & Wilkins, Philadelphia.
- Dash, R., Datta, S., & Saha, S. (2020). Capsule networks: A survey and future research directions. *Journal of King Saud University – Computer and Information Sciences*, 32(2), 189–201.
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861–874.
- Finaldi, G. (2024). *Radiology of pulmonary infections*. Elsevier, Amsterdam.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press, Cambridge.
- Griadhi, Y. (2016). Pneumonia: Etiology, symptoms, and clinical management. *Jurnal Kedokteran Klinis*, 5(1), 12–20.
- Hinton, G. E., Sabour, S., & Frosst, N. (2017). Dynamic routing between capsules. In *Advances in Neural Information Processing Systems* (Vol. 30, pp. 3856–3866).

- Joseph, V. R. (2022). Optimal ratio for data splitting. *Journal of Data Science*, 15(3), 531–538.
- Kalyani, G., Janakiramaiah, B., Karuna, A., & Prasad, L. V. N. (2023). Diabetic retinopathy detection and classification using capsule networks. *Complex & Intelligent Systems*, 9(3), 2451–2464.
- Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- LaLonde, R., & Bagci, U. (2018). Capsule networks for medical image segmentation. *Medical Image Analysis*, 52, 197–207.
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324.
- Markoulidakis, S., Rallis, I., Georgoulas, G., Kopsiaftis, G., Doulamis, A., & Doulamis, N. (2021). Performance evaluation metrics in machine learning for healthcare. *Healthcare Informatics Research*, 27(3), 123–134.
- Maulana, A. (2023). Evaluasi performa model deep learning untuk klasifikasi citra medis. *Jurnal Teknologi Informasi*, 19(2), 55–67.
- Mughal, T., Shaukat, K., Luo, S., Varadharajan, V., & Hameed, I. A. (2022). Metrics for binary classification: Accuracy, precision, recall, and F1-score. *International Journal of Computer Applications*, 184(2), 12–20.
- Nair, V., & Hinton, G. E. (2010). Rectified Linear Units improve restricted Boltzmann machines. In *Proceedings of the 27th International Conference on Machine Learning* (pp. 807–814).
- Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., Ding, D., Bagul, A., Langlotz, C., Shpanskaya, K., Lungren, M. P., & Ng, A. Y. (2017). CheXNet: Radiologist-level pneumonia detection on chest X-rays with deep learning. *arXiv preprint arXiv:1711.05225*.
- Sherwood, L. (2016). *Human physiology: From cells to systems*. Cengage Learning, Boston.
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6(60).

- Wang, X., Peng, Y., Lu, L., Lu, Z., Bagheri, M., & Summers, R. M. (2017). ChestX-ray8: Hospital-scale chest X-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases. *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 2097–2106).
- Zhao, Z., Kleinhan, A., Sandhu, G., Patel, I., & Unnikrishnan, K. P. (2019). Capsule networks with max-min normalization. *arXiv preprint arXiv:1903.09662*.