

**KLASIFIKASI PENYAKIT PNEUMONIA: STUDI KASUS
RSUD DR PIRNGADI KOTA MEDAN**

SKRIPSI

DISUSUN OLEH

AYU SYAHFITRI

NPM. 2009020059



UMSU

Unggul | Cerdas | Terpercaya

**PROGRAM STUDI TEKNOLOGI INFORMASI
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA**

MEDAN

2024

**KLASIFIKASI PENYAKIT PNEUMONIA: STUDI KASUS
RSUD DR PIRNGADI KOTA MEDAN**

SKRIPSI

**Diajukan sebagai salah satu syarat untuk memperoleh gelar Sarjana Komputer
(S.Kom) dalam Program Studi Teknologi Informasi pada Fakultas Ilmu
Komputer dan Teknologi Informasi, Universitas Muhammadiyah Sumatera Utara**

AYU SYAHFITRI

NPM. 2009020059

**PROGRAM STUDI TEKNOLOGI INFORMASI
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA
MEDAN**

2023

LEMBAR PENGESAHAN

Judul Skripsi : KLASIFIKASI PENYAKIT PNEUMONIA: STUDI KASUS RSUD DR PIRNGADI KOTA MEDAN

Nama Mahasiswa : AYU SYAHFITRI

NPM : 2009020059

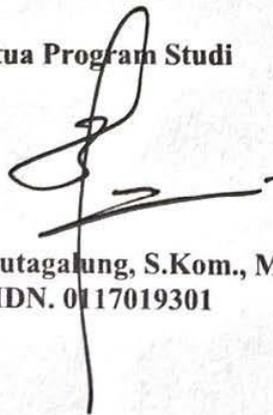
Program Studi : TEKNOLOGI INFORMASI

Menyetujui
Komisi Pembimbing



(Mulkan Azhari, S.kom., M.Kom)
NIDN. 0108129402

Ketua Program Studi



(Fatma Sari Hutagalung, S.Kom., M.Kom.)
NIDN. 0117019301

Dekan



(Dr. Al-Khowarizmi, S.Kom., M.Kom.)
NIDN. 0127099201

PERNYATAAN ORISINALITAS

KLASIFIKASI PENYAKIT PNEUMONIA: STUDI KASUS RSUD DR PIRNGADI KOTA MEDAN

SKRIPSI

Saya menyatakan bahwa karya tulis ini adalah hasil karya sendiri, kecuali beberapa kutipan dan ringkasan yang masing-masing disebutkan sumbernya.

Medan, September 2024

Yang membuat pernyataan



AYU SYAHFITRI

NPM. 2009020059

**PERNYATAAN PERSETUJUAN PUBLIKASI
KARYA ILMIAH UNTUK KEPENTINGAN
AKADEMIS**

Sebagai sivitas akademika Universitas Muhammadiyah Sumatera Utara, saya bertanda tangan dibawah ini:

Nama : Ayu Syahfitri
NPM : 2009020059
Program Studi : Teknologi Informasi
Karya Ilmiah : Skripsi

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Universitas Muhammadiyah Sumatera Utara Hak Bedas Royalti Non-Eksekutif (*Non-Exclusive Royalty free Right*) atas penelitian skripsi saya yang berjudul:

**KLASIFIKASI PENYAKIT PNEUMONIA: STUDI KASUS RSUD DR
PIRNGADI KOTA MEDAN**

Beserta perangkat yang ada (jika diperlukan). Dengan Hak Bebas Royalti Non-Eksekutif ini, Universitas Muhammadiyah Sumatera Utara berhak menyimpan, mengalih media, memformat, mengelola dalam bentuk database, merawat dan mempublikasikan Skripsi saya ini tanpa meminta izin dari saya selama tetap mencantumkan nama saya sebagai penulis dan sebagai pemegang dan atau sebagai pemilik hak cipta.

Demikian pernyataan ini dibuat dengan sebenarnya.

Medan, September 2024

Yang membuat pernyataan



Ayu Syahfitri

NPM. 2009020059

RIWAYAT HIDUP

DATA PRIBADI

Nama Lengkap : AYU SYAHFITRI
Tempat dan Tanggal Lahir : MEDAN, 25-01-2002
Alamat Rumah : TANJUNG MORAWA
Telepon/Faks/HP : 082173967289
E-mail : gustiandrea53@gmail.com
Instansi Tempat Kerja : -
Alamat Kantor : -

DATA PENDIDIKAN

SD : SDN 101882 TAMAT: 2013
SMP : SMP Negeri 4 Tanjung Morawa TAMAT: 2017
SMA : SMA Swasta Nur Azizi TAMAT: 2020

KATA PENGANTAR



Pendahuluan

Penulis tentunya berterima kasih kepada berbagai pihak dalam dukungan serta doa dalam penyelesaian skripsi. Penulis juga mengucapkan terima kasih kepada:

1. Bapak Prof. Dr. Agussani, M.AP., Rektor Universitas Muhammadiyah Sumatera Utara (UMSU)
2. Bapak Dr. Al-Khowarizmi, S.Kom., M.Kom. Dekan Fakultas Ilmu Komputer dan Teknologi Informasi (FIKTI) UMSU.
3. Ibu Fatma Sari Hutagalung, S.Kom, M.Kom. Ketua Program Studi Teknologi.
4. Bapak Mhd. Basri, S.Si, M.Kom. Sekretaris Program Studi Teknologi Informasi
5. Pembimbing Bapak Mulkan Azhari, S.kom, M.Kom selaku pembimbing saya untuk membuat skripsi ini.
6. Kepada ayah dan ibu saya yaitu Alm Bapak Bahrumsyah dan Ibu Siti Aisyah yang selalu mendorong saya untuk melakukan kebaikan, selalu menyupport saya dalam perkuliahan saya, dan juga selalu jadi garda terdepan untuk saya.
7. Kepada saudara laki laki saya yaitu Rahmad Hidayat, S.E beribu kata kata untuk memotivasi adiknya agar selalu dimelakukan hal yang terbaik.
8. Kepada hal-hal baik yang telah datang dan selalu menemani saya dalam melakukan penulisan skripsi ini dan menemani saya mengurus semua berkas tidak kenal panas atau pun hujan, hal baik itu yang bernama Gusti Andrian Gunawan.

9. Semua pihak yang terlibat langsung ataupun tidak langsung yang tidak dapat penulis ucapkan satu-persatu yang telah membantu penyelesaian skripsi ini.

KLASIFIKASI PENYAKIT PNEUMONIA: STUDI KASUS RSUD DR PIRNGADI KOTA MEDAN

ABSTRAK

Pneumonia adalah infeksi pada paru-paru yang disebabkan oleh bakteri, virus, atau jamur, yang menyebabkan peradangan dan penumpukan cairan di alveoli, kantong udara kecil di paru-paru. Gejala umum termasuk batuk, demam, sesak napas, dan nyeri dada. Penyakit ini dapat bervariasi dari ringan hingga berat, dan berisiko tinggi pada bayi, lansia, serta individu dengan sistem kekebalan tubuh yang lemah. Karena *pneumonia* dapat berpotensi berbahaya dan mengancam nyawa, identifikasi dan penanganan dini sangat penting. Klasifikasi citra adalah metode efektif untuk mengidentifikasi pneumonia, dengan membangun model yang dapat mengenali pola dari data citra *X-ray* dan memberikan diagnosis awal berdasarkan citra *X-Ray* yang diinputkan. Dalam penelitian ini, akan melakukan proses Pembangunan model klasifikasi *pneumonia* dengan menggunakan metode *Reccurent Neural Network* (RNN) dan *Syntetic Minority Over-Sampling* (SMOTE). Dalam penelitian ini, proses Pembangunan model akan menggunakan *dataset* yang dikumpulkan dari RSUD Dr. Pirngadi Kota Medan, yang Dimana berjumlah total 5840 data yang memiliki 2 kelas yaitu kelas data normal dan pneumonia. Yang Dimana kelas normal berisi citra *X-Ray* paru paru normal, sedangkan kelas *pneumonia* berisi data citra *X-Ray* paru paru yang telah terinfeksi *pneumonia*. Tujuan dari dilakukannya penelitian ini yaitu untuk membangun sistem klasifikasi penyakit *pneumonia* sehingga diharapkan dengan adanya sistem yang telah dibangun, diharapkan dapat membantu dalam proses identifikasi pneumonia sehingga bisa diambil penanganan lebih awal. Hasil yang didapatkan dari penelitian ini yaitu proses pengujian model dengan menggunakan metode RNN dan SMOTE mendapatkan akurasi sebesar 72%.

Kata Kunci: *Pneumonia*; RNN; SMOTE; Klasifikasi Citra; *Machine Learning*

CLASSIFICATION OF PNEUMONIA: A CASE STUDY OF RSUD DR. PIRNGADI MEDAN

ABSTRACT

Pneumonia is a lung infection caused by bacteria, viruses, or fungi, leading to inflammation and fluid accumulation in the alveoli, the small air sacs in the lungs. Common symptoms include cough, fever, shortness of breath, and chest pain. The disease can range from mild to severe and poses a high risk for infants, the elderly, and individuals with weakened immune systems. Given the potential danger and life-threatening nature of pneumonia, early identification and treatment are crucial. Image classification is an effective method for diagnosing pneumonia by building a model that can recognize patterns from X-ray images and provide an early diagnosis based on the input X-ray images. This study aims to develop a pneumonia classification model using Recurrent Neural Networks (RNN) and Synthetic Minority Over-Sampling Technique (SMOTE). The model will be built using a dataset collected from RSUD Dr. Pirngadi Medan, comprising a total of 5,840 images divided into two classes: normal and pneumonia. The normal class contains X-ray images of healthy lungs, while the pneumonia class includes X-ray images of lungs infected with pneumonia. The goal of this research is to build a pneumonia classification system to aid in the early identification and treatment of the disease. The results from testing the model using RNN and SMOTE methods will be reported, including the achieved accuracy of 72%.

Keywords: Pneumonia; RNN; SMOTE; Image Classification; Machine Learning

DAFTAR ISI

LEMBAR PENGESAHAN	Error! Bookmark not defined.
PERNYATAAN ORISINALITAS	iii
KATA PENGANTAR	vi
ABSTRAK.....	viii
ABSTRACT.....	ix
DAFTAR ISI.....	x
DAFTAR TABEL.....	xii
DAFTAR GAMBAR	xiii
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang Masalah.....	1
1.2 Rumusan Masalah	5
1.3 Batasan Masalah.....	6
1.4 Tujuan Penelitian	6
1.5 Manfaat Penelitian	7
BAB II LANDASAN TEORI	8
2.1 <i>Pneumonia</i>	8
2.2 <i>Klasifikasi Citra</i>	9
2.3 <i>Deep Learning</i>	10

2.4	<i>Reccurent Neural Network</i>	11
2.5	<i>Syntetic Minority Over-Sampling</i>	14
2.6	<i>Confusion Matrix</i>	15
2.7	<i>Python</i>	17
2.8	Penelitian Terkait	18
BAB III METODOLOGI PENELITIAN		24
3.1	Instrumen Penelitian	24
3.2	Pengumpulan Data	25
3.3	Metode yang Diusulkan	25
BAB IV HASIL DAN PEMBAHASAN		31
4.1	Analisis Data	31
4.2	Analisis Layer RNN	48
4.3	Hasil Pengujian	51
4.4	Implementasi Sistem	61
BAB V PENUTUP		68
5.1	Kesimpulan	68
5.2	Saran	69
DAFTAR PUSTAKA		70

DAFTAR TABEL

Tabel 2. 1. Penelitian Terkait	21
Tabel 3. 1. Tabel Instrumen Penelitian.....	24
Tabel 4. 1. Visualisasi kelas <i>dataset</i>	32
Tabel 4. 2. Visualisasi data hasil SMOTE.....	39
Tabel 4. 3. Hasil Pengujian Model	58
Tabel 4. 4. Hasil pengujian lanjutan.....	59

DAFTAR GAMBAR

Gambar 2. 1. Proses Klasifikasi Citra	9
Gambar 2. 2. Visualisasi kerja RNN	12
Gambar 2. 3. Visualisasi <i>Confusion Matrix</i>	15
Gambar 3. 1. Alur Penelitian.....	27
Gambar 3. 2. Layer RNN yang digunakan	29
Gambar 4. 1. Persebaran data awal	38
Gambar 4. 2. Persebaran data hasil SMOTE	48
Gambar 4. 3. Layer penelitian	49
Gambar 4. 4. Hasil proses pelatihan dan validasi	52
Gambar 4. 5. Hasil loss pelatihan dan validasi.....	54
Gambar 4. 6. Hasil <i>confusion matrix</i> pengujian	56
Gambar 4. 7. Tampilan <i>wesbite</i> 1	62
Gambar 4. 8. Tampilan <i>wabsite</i> 2.....	63
Gambar 4. 9. Tampilan <i>website</i> 3	65
Gambar 4. 10. Tampilan <i>website</i> 4.....	66
Gambar 4. 11. Tampilan <i>website</i> 5.....	67

BAB I

PENDAHULUAN

1.1 Latar Belakang Masalah

Pneumonia merupakan penyakit infeksi paru-paru yang dapat menimbulkan dampak kesehatan yang signifikan, dan merupakan salah satu penyebab utama kematian di seluruh dunia (Huang et. all, 2022). Infeksi ini terjadi ketika patogen, seperti bakteri, virus, atau jamur, menyerang *alveoli*, yaitu kantung udara kecil di dalam paru-paru yang berfungsi sebagai tempat pertukaran oksigen dan karbon dioksida (murphy et. all, 2020). Ketika *alveoli* terinfeksi, mereka dapat mengalami peradangan dan pengisian dengan cairan atau nanah, yang mengganggu proses respirasi dan mengurangi kemampuan tubuh untuk mendapatkan oksigen yang cukup (Cinar et. al, 2021). Infeksi ini biasanya disebabkan oleh patogen seperti bakteri, virus, atau jamur, yang menginfeksi *alveoli*, yaitu kantung udara kecil di paru-paru. *Alveoli* yang terinfeksi akan mengalami peradangan dan pengisian dengan cairan atau nanah, mengakibatkan gangguan dalam proses pertukaran oksigen dan karbon dioksida. Angka kematian akibat *pneumonia* sangat mencolok, terutama di kalangan anak-anak.

Data global menunjukkan bahwa *pneumonia* bertanggung jawab atas sekitar 1,4 juta kematian anak-anak setiap tahun. Dari jumlah tersebut, 18% adalah anak-anak di bawah usia lima tahun, yang menunjukkan betapa rentannya kelompok usia ini terhadap penyakit tersebut (Rahman et. all, 2020). Lebih jauh lagi, data dari tahun 2017 menunjukkan bahwa *pneumonia* mengakibatkan kematian sebanyak 808.694 orang di seluruh dunia, menegaskan pentingnya tindakan pencegahan dan pengobatan yang efektif (Alsharif et. all, 2021). Oleh karena itu, *Pneumonia* diakui sebagai penyakit yang mengancam jiwa oleh Organisasi Kesehatan Dunia (WHO), dengan lebih dari satu juta kematian dini setiap tahun disebabkan oleh infeksi ini (Shah et. all, 2020). Risiko

kematian akibat *pneumonia* sangat tinggi bagi individu dengan sistem kekebalan tubuh yang lemah, seperti penderita penyakit kronis, perokok, dan mereka yang memiliki gangguan pernapasan (Chouhan et. al, 2020). Karena individu ini memiliki paru paru yang rentan sehingga dapat mempercepat infeksi *pneumonia* menjadi lebih parah. Dilain sisi, penyakit *pneumonia* tercatat juga sebagai penyebab utama kematian pada anak-anak di Asia Selatan dan Afrika Sub-Sahara. Angka kematian yang tinggi di wilayah-wilayah ini sering kali terkait dengan kurangnya akses ke fasilitas kesehatan yang memadai, vaksinasi, dan pengobatan yang efektif (Jain et. all, 2020). Di daerah-daerah ini, *pneumonia* tidak hanya menjadi masalah kesehatan tetapi juga masalah sosial-ekonomi yang besar. Meskipun *pneumonia* dapat diobati dengan berbagai jenis antibiotik, *antivirals*, dan terapi lainnya, efektivitas pengobatan sangat tergantung pada waktu diagnosis dan inisiasi terapi (Ayan et. all, 2019). Pengobatan yang cepat dan tepat sangat penting untuk mengurangi risiko komplikasi serius dan meningkatkan kemungkinan kesembuhan (Rahman et. all, 2020). Oleh karena itu, untuk melakukan pengobatan yang cepat, diperlukan juga proses identifikasi yang tepat dan akurat sehingga bisa memberikan diagnosis yang baik.

Klasifikasi citra merupakan proses untuk memprediksi data berdasarkan label yang ada (Moen et. all, 2019). Proses klasifikasi ini dilakukan menggunakan berbagai pendekatan, seperti menggunakan algoritma untuk mencari pola dari data, proses menggunakan fitur yang lebih kompleks dan banyak, dan sebagainya (Canedo et. all, 2020). Klasifikasi citra merupakan bagian dari pemrosesan citra digital, yang Dimana merupakan bidang ilmu untuk dapat melakukan pengolahan dari citra dan mengestrak informasi yang berguna dari citra (Jumadi et. all, 2021). Oleh karena itu, metode klasifikasi citra ini cocok untuk digunakan sehingga dapat memahami pola dari citra *X-Ray* dan dapat dilakukan proses diagnosis penyakit *pneumonia* dengan baik. Selanjutnya, Pemrosesan citra adalah bagian dari kecerdasan buatan yang melakukan proses perbaikan dan analisis gambar. Dalam implementasinya, karena termasuk kedalam bagian

kecerdasan buatan atau *Artificial Intelligence* (AI), maka dalam proses klasifikasi citra diperlukan metode untuk dapat mempelajari pola dari data.

Deep learning merupakan cabang dari kecerdasan buatan (AI) yang berfokus pada penggunaan jaringan saraf tiruan dengan banyak lapisan (*deep neural networks*) untuk menganalisis dan memproses data (Kufel et. all, 2023). Konsep utamanya melibatkan arsitektur jaringan saraf yang terdiri dari beberapa lapisan tersembunyi antara input dan *output*, yang memungkinkan model untuk belajar representasi data yang semakin kompleks dari data mentah. Proses ini melibatkan penggunaan algoritma pembelajaran yang mendalam untuk melatih jaringan saraf pada data besar dan beragam, sehingga jaringan dapat mengidentifikasi pola, fitur, dan hubungan yang sulit dideteksi dengan metode tradisional (Dong et. all, 2021). *Deep learning* sangat efektif dalam tugas-tugas seperti pengenalan gambar, pemrosesan bahasa alami, dan prediksi, karena kemampuannya untuk secara otomatis mengekstraksi fitur dari data tanpa memerlukan intervensi manusia (Sharma et. all, 2021). Metode ini mengandalkan teknik seperti *backpropagation* untuk memperbarui bobot jaringan dan optimasi berbasis gradient untuk meningkatkan akurasi model seiring waktu, sehingga proses prediksi dapat lebih akurat dan baik. *Recurrent Neural Networks* (RNN) merupakan jenis jaringan saraf tiruan yang dirancang khusus untuk memproses data urutan atau data yang memiliki hubungan temporal, seperti teks atau sinyal waktu (Sherstinsky, 2020). Berbeda dengan jaringan saraf tradisional, RNN memiliki koneksi yang kembali (*recurrent connections*) yang memungkinkan informasi dari langkah sebelumnya untuk mempengaruhi langkah berikutnya dalam urutan (Yadav et. all, 2022). Hal ini dicapai dengan cara menyimpan keadaan internal (*hidden state*) yang memuat informasi dari langkah sebelumnya dan menggunakannya dalam langkah-langkah berikutnya. Struktur ini memungkinkan RNN untuk menangkap ketergantungan temporal dan pola yang ada dalam data urutan. Namun, RNN dasar sering menghadapi masalah seperti *vanishing gradient* dan *exploding gradient* yang dapat menghambat pelatihan untuk urutan data yang panjang.

Dalam proses Pembangunan model, diperlukan data yang baik untuk bisa digunakan dalam proses pelatihan sehingga model dapat menangkap pola informasi dari data dengan baik. Salah satu tahapan yang dapat dilakukan yaitu menyeimbangkan data pada setiap kelas, sehingga model dapat mempelajari data pada setiap kelas dengan baik dan tidak bias. Metode penyeimbangan data yang dilakukan dapat menggunakan metode SMOTE (*Syntetic Minority Over-Sampling*). *Synthetic Minority Over-sampling Technique* (SMOTE) merupakan metode *oversampling* yang digunakan untuk menangani masalah ketidakseimbangan kelas dalam *dataset*, terutama ketika terdapat jumlah contoh yang sangat kecil pada kelas minoritas dibandingkan dengan kelas mayoritas (Wang et. all, 2021). SMOTE bekerja dengan menghasilkan contoh sintetik baru untuk kelas minoritas dengan cara interpolasi antara contoh yang ada (Dablain et. all, 2021). Proses ini dimulai dengan memilih contoh dari kelas minoritas dan menemukan tetangga terdekatnya. Kemudian, SMOTE membuat contoh sintetik dengan menginterpolasi antara contoh tersebut dan tetangganya dengan menggunakan kombinasi linear dari fitur-fitur yang ada. Hal ini dilakukan dengan memilih titik acak di antara contoh yang ada dan tetangganya, sehingga menghasilkan data sintetik yang mirip tetapi tidak identik dengan data asli. Metode ini meningkatkan representasi kelas minoritas dalam dataset, yang membantu model untuk belajar lebih baik dan mengurangi bias terhadap kelas mayoritas, sehingga memperbaiki performa dalam pengklasifikasian data.

Dalam penelitian ini, akan dilakukan proses Pembangunan sistem klasifikasi penyakit *pneumonia* dengan menggunakan metode *deep learning* RNN dan SMOTE berdasarkan citra *X-Ray* pasien. Tujuan menggunakan *Recurrent Neural Networks* (RNN) dalam klasifikasi *pneumonia* berdasarkan citra *X-ray* adalah untuk memanfaatkan kemampuan RNN dalam menganalisis pola temporal dan fitur yang dapat muncul dalam urutan gambar *X-ray* atau serangkaian citra dari satu pasien. Dengan mengintegrasikan informasi dari citra-citra tersebut, RNN dapat meningkatkan akurasi diagnosis dengan mengidentifikasi pola yang mungkin terlewat jika hanya mengandalkan teknik klasifikasi

gambar statis. Sedangkan, tujuan menggunakan metode SMOTE yaitu untuk melakukan proses penyeimbangan data pada setiap kelas, dikarenakan persebaran data normal dan *pneumonia* tidak seimbang, sehingga dapat menimbulkan bias. Sehingga, dengan adanya sistem yang dibangun pada penelitian ini diharapkan dapat membantu tenaga medis dalam melakukan proses diagnosa penyakit *pneumonia* dan dapat membantu sehingga penanganan dilakukan lebih cepat.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah dipaparkan sebelumnya, penelitian ini bertujuan untuk membangun suatu sistem yang dapat mengatasi masalah dan memberikan Solusi dalam proses klasifikasi penyakit *pneumonia* menggunakan citra *X-Ray*. Untuk rumusan masalah dari penelitian ini diberikan berikut.

1. Bagaimana membangun model klasifikasi *pneumonia* yang dengan memanfaatkan metode *deep learning*, khususnya *Recurrent Neural Networks* (RNN), yang mampu mengidentifikasi pola-pola temporal dalam citra *X-ray* pasien?
2. Bagaimana metode SMOTE dapat digunakan untuk mengatasi ketidakseimbangan kelas pada *dataset* citra *X-ray pneumonia*, dan sejauh mana metode ini dapat meningkatkan performa model dalam mengklasifikasikan penyakit *pneumonia*?
3. Sejauh mana performa RNN dalam sistem klasifikasi *pneumonia* yang dibangun dalam melakukan diagnosis penyakit *pneumonia* secara lebih cepat dan akurat di RSUD DR PIRNGADI KOTA MEDAN untuk prediksi *pneumonia*?

1.3 Batasan Masalah

Berdasarkan pada latar belakang serta rumusan masalah yang telah dipaparkan sebelumnya, maka untuk proses pengembangan sistem terdapat beberapa Batasan masalah yang terdapat pada penelitian ini.

1. *Dataset* yang digunakan merupakan *dataset* yang didapatkan dari pengumpulan data citra *X-Ray pneumonia* dan normal dari RSUD Dr Pengadi Medan.
2. *Dataset* yang digunakan berjumlah sebanyak 5840 data citra dengan data pelatihan sebanyak 5216 data dan data pengujian sebanyak 624 data.
3. Data yang digunakan baik untuk proses pelatihan dan pengujian model memiliki 2 kelas yaitu kelas *pneumonia* dan kelas normal dengan persebaran data pelatihan sebanyak 3875 data kelas *pneumonia* dan 1341 kelas normal serta persebaran data pengujian sebanyak 390 data kelas *pneumonia* dan 234 data kelas normal.
4. Data yang digunakan merupakan data citra dengan ekstensi .jpeg.
5. Metode yang digunakan untuk melakukan penyeimbangan data pada setiap kelas yaitu *Syntetic Minority Over-Sampling (SMOTE)*.
6. Metode yang digunakan untuk melakukan proses klasifikasi data yaitu menggunakan *Reccurent Neural Network (RNN)*.
7. Implementasi dan Pembangunan sistem akan menggunakan Bahasa pemrograman *python* serta *website* akan menggunakan *streamlit*.

1.4 Tujuan Penelitian

Berdasarkan pada paparan yang telah diberikan sebelumnya, dilakukannya penelitian ini bertujuan untuk:

1. Melakukan proses implementasi metode (RNN) dan *Reccurent Neural Network Syntetic Minority Over-Sampling (SMOTE)* dalam melakukan klasifikasi penyakit *pneumonia*.

2. Mengetahui bagaimana performa metode *Reccurent Neural Network* dalam menangkap pola dan informasi dari data citra *X-Ray* untuk diolah sehingga dapat melakukan proses klasifikasi penyakit *pneumonia*.
3. Mengetahui bagaimana efektivitas metode *Syntetic Minority Over-Sampling* dalam menambahkan data sintetis guna menyeimbangkan jumlah data pada setiap kelas dan membantu model menangkap pola yang lebih baik dari data.

1.5 Manfaat Penelitian

Setelah dilakukan identifikasi dan ditetapkan beberapa Batasan yang ada pada penelitian ini, maka dapat diberikan manfaat dari dilakukannya penelitian ini yaitu:

1. Memberikan Gambaran mengenai bagaimana efektivitas dan performa metode *Reccurent Neural Network* dalam menangkap serta mempelajari pola dari data citra.
2. Memberikan Gambaran bagaimana dampak dan efektifitas setelah dilakukan implementasi metode *Syntetic Minority Over-Sampling* dalam menyeimbangkan kelas data.
3. Mendukung kemudahan serta menjadi inovasi baru dalam pemeriksaan *pneumonia* melalui analisis citra *X-ray*, memungkinkan pemberian diagnosis awal yang lebih akurat dan mempercepat penanganan, sehingga mencegah kondisi menjadi semakin parah.

BAB II LANDASAN TEORI

2.1 *Pneumonia*

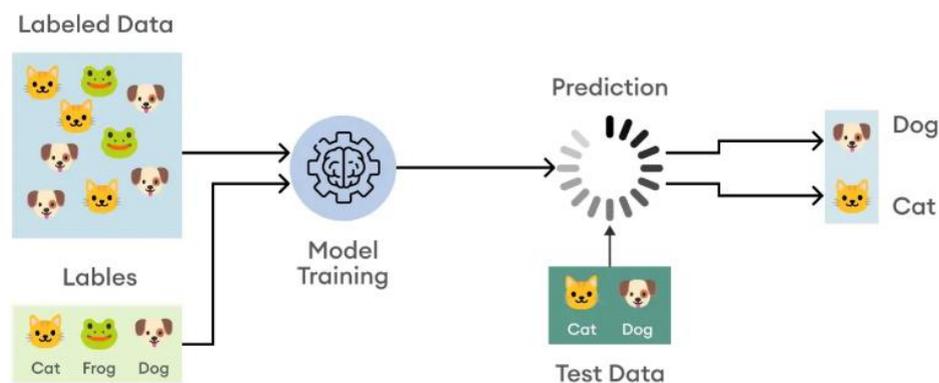
Pneumonia adalah infeksi paru-paru yang dapat mengancam jiwa, terutama karena menyerang *alveoli*, yakni kantung udara kecil di paru-paru yang berperan penting dalam pertukaran oksigen dan karbon dioksida. Ketika patogen seperti bakteri, virus, atau jamur menginfeksi *alveoli*, kantung-kantung ini menjadi meradang dan terisi dengan cairan atau nanah (murphy et. all, 2020). Kondisi ini menghambat pertukaran oksigen yang sangat penting bagi tubuh, menyebabkan gangguan pernapasan serius dan penurunan tajam dalam suplai oksigen ke seluruh organ (Cinar et. al, 2021). Proses infeksi ini tidak hanya merusak *alveoli*, tetapi juga memicu respons inflamasi yang dapat menyebar ke seluruh sistem pernapasan, memperburuk kondisi pasien dan meningkatkan risiko komplikasi.

Pneumonia merupakan penyebab kematian utama di seluruh dunia, terutama di kalangan anak-anak. Menurut data global, penyakit ini bertanggung jawab atas kematian sekitar 1,4 juta anak setiap tahun, dengan 18% di antaranya terjadi pada anak-anak di bawah usia lima tahun, menandakan kerentanan yang sangat tinggi pada kelompok usia ini (Rahman et. all, 2020). Di wilayah Asia Selatan dan Afrika Sub-Sahara, *pneumonia* menjadi penyebab utama kematian pada anak-anak, didorong oleh kurangnya akses ke layanan kesehatan yang memadai, vaksinasi, dan pengobatan yang efektif (Jain et. all, 2020). Tingginya angka kematian di wilayah ini juga terkait dengan faktor sosial-ekonomi, di mana penyakit ini tidak hanya menjadi masalah kesehatan tetapi juga memperparah ketidaksetaraan sosial dan ekonomi. Meskipun pengobatan *pneumonia* tersedia dan biasanya melibatkan penggunaan antibiotik, *antivirals*, dan terapi lain, keberhasilan pengobatan sangat bergantung pada kecepatan diagnosis dan inisiasi terapi. Identifikasi yang cepat dan akurat sangat penting untuk memulai pengobatan dengan

segera, sehingga dapat mengurangi risiko komplikasi serius dan meningkatkan peluang kesembuhan pasien (Ayan et. all, 2019).

2.2 Klasifikasi Citra

Klasifikasi citra adalah proses dalam pengolahan gambar yang bertujuan untuk mengidentifikasi dan mengategorikan objek atau fitur yang terdapat dalam citra digital ke dalam kelas-kelas tertentu (Moen et. all, 2019). Proses ini melibatkan ekstraksi fitur dari citra, seperti pola warna, tekstur, dan bentuk, kemudian menggunakan fitur-fitur ini untuk menentukan kelas atau kategori citra berdasarkan data pelatihan yang telah ada (Canedo et. all, 2020). Untuk visualisasi proses klasifikasi citra diberikan pada gambar 2. 1.



Gambar 2. 1. Proses Klasifikasi Citra

Klasifikasi citra sangat penting dalam berbagai aplikasi, mulai dari pengenalan wajah dan analisis medis hingga deteksi objek dalam video dan pengawasan lingkungan. Selama proses klasifikasi, model yang digunakan akan mempelajari karakteristik dari berbagai kelas citra melalui algoritma pembelajaran mesin, kemudian menerapkan pengetahuan ini untuk mengklasifikasikan citra baru secara akurat. Dengan kemajuan teknologi dan algoritma, klasifikasi citra telah menjadi lebih canggih, mampu menangani

kompleksitas visual yang tinggi dan memberikan hasil yang lebih akurat dalam berbagai konteks penelitian.

2.3 Deep Learning

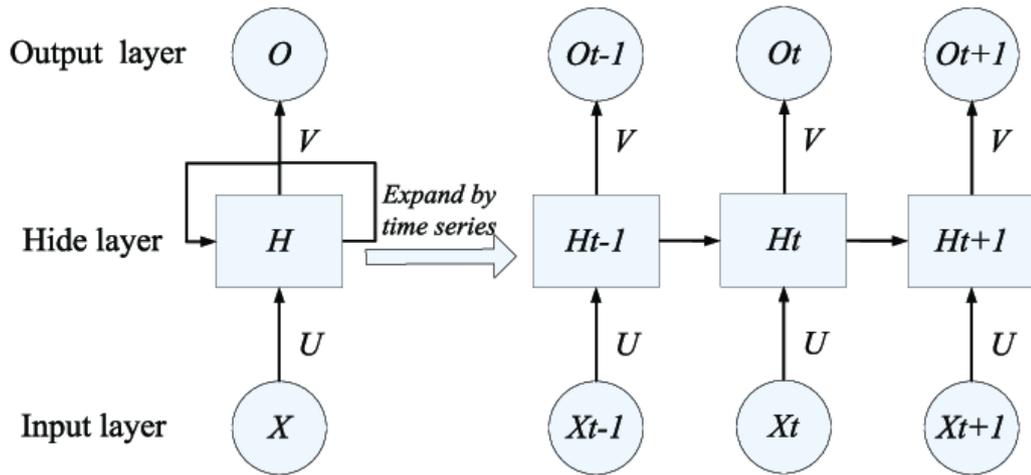
Kecerdasan Buatan (*Artificial Intelligence/AI*) merupakan cabang ilmu komputer yang berfokus pada pengembangan sistem yang dapat melakukan tugas-tugas yang biasanya membutuhkan kecerdasan manusia (Rifky et. all, 2024). AI mencakup berbagai teknologi dan metode, termasuk pembelajaran mesin (*machine learning*), di mana komputer dilatih untuk mengenali pola dalam data dan membuat keputusan berdasarkan pola tersebut. AI digunakan dalam berbagai aplikasi, mulai dari sistem rekomendasi di platform *e-commerce* hingga kendaraan otonom (Zebua et. all, 2024). Tujuan utama AI adalah menciptakan sistem yang dapat belajar, beradaptasi, dan membuat keputusan secara mandiri tanpa intervensi manusia. *Image processing* atau pengolahan citra adalah proses mengolah gambar untuk meningkatkan kualitasnya atau mengekstrak informasi yang bermanfaat (Ngugi et. all, 2021). Dalam *image processing*, gambar diubah atau dianalisis untuk mencapai tujuan tertentu, seperti meningkatkan kejernihan gambar, mendeteksi objek, atau mengenali pola (Jasim et. all, 2020). Pengolahan citra digunakan dalam berbagai bidang, termasuk medis, di mana teknik ini diterapkan untuk menganalisis citra medis seperti *MRI* dan *X-ray*, serta dalam pengawasan keamanan melalui analisis citra video. *Deep learning*, sebagai cabang dari pembelajaran mesin, sangat berperan dalam kemajuan *image processing*.

Deep learning adalah subbidang dari pembelajaran mesin (*machine learning*) yang berfokus pada model-model berbasis jaringan saraf tiruan yang memiliki banyak lapisan (*layer*) pemrosesan (Roberts et. all, 2022). Model ini dirancang untuk meniru cara kerja otak manusia dalam memproses data, belajar dari pengalaman, dan membuat keputusan. Di dalam *deep learning*, jaringan saraf tiruan ini belajar secara hierarkis, di mana setiap

lapisan bertanggung jawab untuk mengekstrak fitur atau pola tertentu dari data yang diberikan, mulai dari fitur yang sederhana hingga yang lebih kompleks (Janiesch et. all, 2021). Keunggulan *deep learning* terletak pada kemampuannya untuk mengolah sejumlah besar data dan secara otomatis menemukan representasi data yang berguna tanpa perlu intervensi manusia dalam proses ekstraksi fitur (Wang et. all, 2021). Ini membuat *deep learning* sangat efektif untuk berbagai aplikasi yang melibatkan data yang sangat kompleks, seperti gambar, suara, dan teks. Teknologi ini telah merevolusi banyak bidang, termasuk pengenalan suara, pemrosesan bahasa alami, dan pengolahan citra, karena kemampuannya untuk mencapai tingkat akurasi yang sangat tinggi dalam tugas-tugas yang sulit untuk dipecahkan oleh metode pembelajaran mesin yang tradisional.

2.4 *Reccurent Neural Network*

Recurrent Neural Networks (RNN) adalah jenis jaringan saraf tiruan yang sangat efektif untuk memproses data berurutan, seperti teks, sinyal suara, atau bahkan citra yang memiliki struktur berurutan (Ullah et. all, 2022). Dalam konteks klasifikasi citra, RNN digunakan untuk menangkap hubungan temporal atau spasial yang ada dalam citra, terutama ketika citra tersebut diproses dalam potongan-potongan sekuensial (Kanakala et. all, 2023). Misalnya, citra dapat dipecah menjadi beberapa bagian, seperti baris atau kolom piksel, yang kemudian diolah oleh RNN secara berurutan. Untuk visualisasi kerja RNN diberikan pada gambar 2.2.



Gambar 2. 2. Visualisasi kerja RNN

Gambar 2.2 menunjukkan visualisasi kerja RNN. Dalam RNN, arsitekturnya memiliki mekanisme umpan balik, yang memungkinkan jaringan untuk mempertahankan "memori" dari input sebelumnya saat memproses input baru. Mekanisme ini dicapai dengan menghubungkan status tersembunyi (*hidden state*) dari satu waktu ke waktu berikutnya, memungkinkan informasi dari waktu sebelumnya untuk mempengaruhi keputusan di waktu berikutnya. Rumus matematis yang menggambarkan pembaruan status tersembunyi dalam RNN pada waktu t diberikan pada poin 1.

$$h_t = \sigma(W_h * x_t + U_h * h_{t-1} + b_h) \quad (1)$$

Poin 1 menggambarkan rumus matematis dari proses metode *Recurrent Neural Network*. Dapat dilihat pada poin 1, h_t merupakan status tersembunyi pada runtutan waktu atau t , x_t merupakan input yang diberikan pada waktu t , h_{t-1} merupakan status tersembunyi dari waktu sebelumnya, W_h serta U_h yaitu merupakan matriks bobot yang perlu dipelajari oleh model RNN, b_h adalah *vector bias* dan σ merupakan fungsi aktivasi *non-linear* seperti *sigmoid* atau *tanh*. Setelah memproses seluruh urutan input, status

tersembunyi terakhir h_t (di mana t merupakan panjang urutan) sering kali digunakan sebagai representasi yang mengandung informasi urutan input. Dalam tugas klasifikasi, representasi ini kemudian dapat digunakan sebagai input ke lapisan *softmax* untuk menghasilkan distribusi probabilitas di antara kelas-kelas yang berbeda. Untuk rumus representasi metode *softmax* dalam menghasilkan probabilitas kelas diberikan pada poin 2.

$$y = \text{softmax}(W_o * h_T + b_o) \quad (1)$$

Poin 2 menunjukkan perhitungan representasi metode *softmax* dalam menghasilkan probabilitas setiap kelas dari data. Dapat dilihat pada poin 2, W_o merupakan matriks bobot untuk lapisan *output*, b_o merupakan *vector bias* yang ada untuk lapisan *output* dan *softmax* adalah fungsi aktivasi yang menghasilkan distribusi probabilitas untuk setiap kelas. Dalam kasus klasifikasi citra, *output* dari layer RNN terakhir (yaitu y , di mana T merupakan panjang sekuens) biasanya diumpankan ke lapisan *Dense (fully connected)* untuk menghasilkan prediksi akhir berdasarkan kelas yang diinginkan. Namun, RNN memiliki beberapa kelemahan, terutama ketika berhadapan dengan urutan panjang. Salah satu masalah utama yang dihadapi oleh RNN adalah *vanishing gradient problem*. Ini terjadi selama proses pelatihan di mana gradien yang dihitung menjadi sangat kecil (atau sangat besar), menyebabkan bobot di lapisan-lapisan awal tidak diperbarui secara efektif. Secara umum, RNN adalah model yang kuat untuk menangani data sekuensial dan temporal, namun mereka memiliki keterbatasan dalam klasifikasi citra statis. Mereka lebih cocok untuk tugas-tugas di mana informasi kontekstual dari data sekuensial diperlukan, seperti analisis video, pemodelan bahasa, dan pengenalan pola pada data deret waktu.

2.5 *Syntetic Minority Over-Sampling*

SMOTE (*Synthetic Minority Over-sampling Technique*) merupakan sebuah metode yang digunakan untuk mengatasi masalah ketidakseimbangan kelas dalam *dataset*, terutama dalam konteks pembelajaran mesin (Ishaq et. all, 2021). Ketidakseimbangan kelas terjadi ketika salah satu kelas dalam *dataset* memiliki jumlah sampel yang jauh lebih sedikit dibandingkan dengan kelas lainnya, yang dapat menyebabkan model menjadi bias dan cenderung mengabaikan kelas minoritas. SMOTE bekerja dengan menciptakan sampel sintetis untuk kelas minoritas, bukan hanya dengan menduplikasi sampel yang ada, tetapi dengan menghasilkan sampel baru berdasarkan interpolasi antara sampel minoritas yang ada (Li et. all, 2021). Proses ini dilakukan dengan memilih sampel acak dari kelas minoritas dan kemudian menghitung vektor perbedaan antara sampel tersebut dan tetangganya yang terdekat. Sampel sintetis kemudian dihasilkan dengan menambahkan vektor perbedaan ini ke sampel asli dengan bobot acak yang berada di antara 0 dan 1. Untuk rumus perhitungan SMOTE dalam melakukan generate data sintetis diberikan pada poin 3.

$$x_{baru} = x_i + (x_{nn} - x_i) * \delta \quad (3)$$

Poin 3 menunjukkan rumus perhitungan SMOTE dalam melakukan pembuatan data sintetis baru. Dapat dilihat pada poin 3, Dimana x_i merupakan vektor fitur dari sampel minoritas asli, x_{nn} merupakan vektor fitur dari salah satu tetangga terdekat x_i yang dipilih secara acak dan δ merupakan bilangan acak yang berada dalam rentang angka 0 dan 1 yang menentukan seberapa jauh sampel sintetis akan berada di sepanjang garis antara x_i dan x_{nn} untuk dapat menghasilkan data sintetis. Proses ini diulangi untuk setiap sampel minoritas sampai jumlah sampel kelas minoritas mendekati atau sama dengan

jumlah sampel di kelas mayoritas, dengan tujuan untuk mengurangi ketidakseimbangan kelas dalam dataset.

2.6 Confusion Matrix

Confusion Matrix adalah alat penting dalam evaluasi kinerja model klasifikasi, terutama ketika berhadapan dengan dataset yang memiliki lebih dari dua kelas atau ketika kelas-kelasnya tidak seimbang (Xu et. all, 2020). Matrix ini terdiri dari empat komponen utama: *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN) (Hasnain et, all, 2020). *True Positive* (TP) adalah jumlah prediksi di mana model dengan benar mengidentifikasi kelas positif (misalnya, mengklasifikasikan penyakit ketika pasien benar-benar sakit). *True Negative* (TN) adalah jumlah prediksi di mana model dengan benar mengidentifikasi kelas negatif (misalnya, mengklasifikasikan tidak adanya penyakit ketika pasien benar-benar sehat). *False Positive* (FP) adalah kasus di mana model salah mengklasifikasikan kelas negatif sebagai positif (misalnya, mengklasifikasikan pasien sehat sebagai sakit), sedangkan *False Negative* (FN) adalah kasus di mana model salah mengklasifikasikan kelas positif sebagai negatif (misalnya, mengklasifikasikan pasien sakit sebagai sehat). Contoh *confusion matrix* diberikan pada gambar 2.3.

		<i>Predicted class</i>	
		<i>P</i>	<i>N</i>
<i>Actual Class</i>	<i>P</i>	True Positives (TP)	False Negatives (FN)
	<i>N</i>	False Positives (FP)	True Negatives (TN)

Gambar 2. 3. Visualisasi Confusion Matrix

Dengan *Confusion Matrix*, kita bisa memperoleh berbagai metrik evaluasi yang memberikan wawasan lebih dalam tentang performa model daripada hanya melihat akurasi saja. *Precision* adalah metrik yang digunakan untuk mengukur seberapa tepat prediksi positif yang dibuat oleh model (Ramli et. all, 2023). *Precision* berfokus pada akurasi dari prediksi yang dikategorikan sebagai positif oleh model, dengan menghitung proporsi dari prediksi positif yang benar-benar positif. Untuk rumus precision diberikan pada poin 4.

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

Poin 4 menunjukkan rumus perhitungan presisi. Semakin tinggi nilai *Precision*, semakin sedikit model melakukan kesalahan dalam mengidentifikasi sampel yang sebenarnya negatif sebagai positif, yang berarti model lebih dapat diandalkan dalam memberikan prediksi positif. *Recall*, juga dikenal sebagai *Sensitivity* atau *True Positive Rate*, mengukur seberapa baik model dalam menangkap semua sampel positif (Riehl et. all, 2023). *Recall* memberikan gambaran tentang kemampuan model dalam mengidentifikasi semua sampel yang seharusnya diklasifikasikan sebagai positif. Untuk rumus perhitungan *recall* diberikan pada poin 5.

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

Poin 5 menggambarkan perhitungan matematis nilai *recall*. *Recall* tinggi menunjukkan bahwa model mampu menangkap hampir semua kasus positif, meskipun mungkin harus mengorbankan sedikit presisi, artinya model mungkin juga akan mengidentifikasi beberapa sampel negatif sebagai positif. *F1-Score* adalah metrik yang

menggabungkan *Precision* dan *Recall* menjadi satu angka tunggal yang memberikan keseimbangan antara keduanya. *F1-Score* sangat berguna dalam situasi di mana ada ketidakseimbangan kelas atau ketika kedua metrik, *Precision* dan *Recall* (Chicco et. all, 2020). Untuk rumus perhitungan *F1-Score* diberikan pada poin 6.

$$F1 - score = \frac{2 * (Precision * Recall)}{(Precision + Recall)} \quad (6)$$

Poin 6 menggambarkan perhitungan matematis mengenai nilai *f1-score*. Berdasarkan nilai *f1-score*, Jika *Precision* dan *Recall* keduanya tinggi, *F1-Score* juga akan tinggi, menunjukkan bahwa model memiliki kinerja yang baik dalam hal prediksi positif yang benar dan dalam mendeteksi semua sampel positif.

2.7 Python

Python adalah bahasa pemrograman tingkat tinggi yang sangat populer karena kesederhanaan sintaksnya dan kemampuannya untuk menangani berbagai jenis tugas pemrograman, dari pengembangan *website* hingga analisis data dan pembelajaran mesin (Ritonga et. all, 2023). Dikembangkan oleh Guido van Rossum dan pertama kali dirilis pada tahun 1991, *Python* dirancang untuk memiliki sintaks yang mudah dipahami, memungkinkan para pemrogram untuk mengekspresikan konsep-konsep mereka dengan lebih sedikit baris kode dibandingkan dengan bahasa seperti *C++* atau *Java*. Bahasa ini mendukung berbagai paradigma pemrograman, termasuk pemrograman berorientasi objek, prosedural, dan fungsional, sehingga fleksibel untuk berbagai aplikasi. Selain itu, *Python* memiliki komunitas yang sangat aktif dan ekosistem pustaka yang luas.

Python juga dikenal dengan dukungannya yang kuat untuk integrasi dan interoperabilitas, memungkinkan pengguna untuk menghubungkan berbagai sistem dan perangkat lunak dengan mudah (Kauhanen et. all, 2021). Misalnya, *Python* dapat

digunakan untuk mengotomatisasi tugas-tugas administratif, membangun aplikasi *website* melalui kerangka kerja seperti Django atau Flask, dan mengembangkan algoritma kecerdasan buatan. Dengan adanya *interpreter* yang tersedia untuk hampir semua sistem operasi, seperti *Windows*, *macOS*, dan *Linux*, *Python* menjadi bahasa yang sangat portabel. Selain itu, *Python* memiliki fitur manajemen emori otomatis dan penanganan kesalahan yang kuat, yang membantu dalam pengembangan aplikasi skala besar tanpa harus terlalu khawatir tentang manajemen sumber daya rendah level. Dengan kemudahan penggunaannya, dokumentasi yang ekstensif, dan dukungan komunitas yang besar, *Python* terus berkembang menjadi salah satu bahasa pemrograman paling penting di dunia teknologi.

2.8 Penelitian Terkait

Penelitian yang dilakukan oleh (Manimurungan, 2024) berfokus pada pengembangan metode klasifikasi kanker kulit yang lebih efektif dengan memanfaatkan pendekatan *hybrid* jaringan saraf. Dalam studi ini, peneliti menggunakan kombinasi dari *Context-Aware Convolutional Neural Network (CA-CNN)* dan *Recurrent Neural Network (RNN)* untuk memproses dan menganalisis gambar kulit yang dicurigai mengandung kanker. Tujuan utama dari penggunaan metode *hybrid* ini adalah untuk meningkatkan akurasi dan efisiensi dalam klasifikasi citra, dengan mempertimbangkan konteks spasial dan temporal dari data input. Pendekatan CA-CNN bertanggung jawab untuk menangkap fitur spasial dari gambar kulit, seperti tekstur dan pola, yang penting dalam mendeteksi berbagai jenis kanker kulit. Sementara itu, RNN digunakan untuk memahami ketergantungan sekuensial dan temporal, yang membantu dalam memahami perkembangan atau perubahan yang mungkin terjadi dalam lesi kulit. Hasil penelitian menunjukkan bahwa model CA-CNN-RNN yang diusulkan berhasil mencapai kinerja yang mengesankan dengan akurasi pengujian sebesar 97.14%, yang menandakan

kemampuan model untuk secara tepat mengklasifikasikan gambar kanker kulit. Selain itu, model ini juga mencatatkan nilai presisi sebesar 96.49%, yang menunjukkan kemampuan model untuk mengurangi jumlah positif palsu. Nilai recall yang mencapai 98.21% menekankan efektivitas model dalam mendeteksi kasus-kasus kanker yang sebenarnya, mengurangi jumlah negatif palsu. Terakhir, *f1-score* sebesar 96.50% menunjukkan keseimbangan yang baik antara presisi dan *recall*, menegaskan model ini sebagai solusi yang sangat efektif dan andal dalam diagnosis kanker kulit.

Penelitian yang dilakukan oleh (Imran et. al, 2021) mengeksplorasi proses klasifikasi penyakit katarak dengan memanfaatkan metode *Convolutional Neural Network* (CNN) dan *Recurrent Neural Network* (RNN). Fokus utama dari penelitian ini adalah pengembangan model yang dapat secara efektif dan akurat mengklasifikasikan penyakit katarak berdasarkan data medis yang diberikan. Dalam kajian ini, peneliti mengintegrasikan CNN dan RNN untuk mengoptimalkan proses klasifikasi. CNN, yang dikenal efektif dalam ekstraksi fitur dari citra medis, digunakan untuk mendeteksi pola-pola visual yang relevan dalam gambar mata pasien. Sementara itu, RNN, dengan kemampuannya untuk memproses data berurutan, digunakan untuk menganalisis data temporal atau sekuensial yang mungkin ada dalam *dataset*. Model yang dikembangkan dalam penelitian ini berhasil mencapai tingkat akurasi pengujian sebesar 97.39%. Angka ini menunjukkan peningkatan signifikan dibandingkan dengan hasil yang diperoleh dalam penelitian sebelumnya. Peningkatan akurasi ini menandakan bahwa kombinasi metode CNN dan RNN dalam model ini mampu meningkatkan kemampuan deteksi dan klasifikasi penyakit katarak dengan lebih baik. Secara keseluruhan, hasil dari penelitian ini memberikan kontribusi penting dalam bidang pengembangan sistem deteksi otomatis untuk penyakit katarak, menawarkan potensi peningkatan dalam akurasi diagnosis dan memberikan panduan yang berguna bagi peneliti dan praktisi di bidang kedokteran mata.

Penelitian yang dilakukan oleh (Yan et. al, 2020) fokus pada proses klasifikasi kanker payudara dengan memanfaatkan metode *hybrid deep neural network*. Penelitian

ini mengadopsi pendekatan yang menggabungkan dua metode utama dalam *deep learning*, yaitu *Convolutional Neural Network* (CNN) dan *Recurrent Neural Network* (RNN). Dalam penelitian ini, CNN digunakan sebagai ekstraktor informasi dari data, terutama untuk menganalisis citra medis. CNN memiliki kemampuan untuk mengidentifikasi fitur-fitur penting dalam gambar dengan akurasi tinggi, yang merupakan langkah awal yang krusial dalam proses klasifikasi. Dengan ekstraksi fitur yang efisien, CNN dapat menangkap pola-pola visual yang relevan yang berkaitan dengan kanker payudara. Setelah ekstraksi fitur oleh CNN, data yang dihasilkan kemudian diproses menggunakan RNN. RNN di sini berfungsi sebagai model klasifikasi yang mampu menganalisis data sekuensial atau temporal, serta menyaring informasi yang relevan untuk menentukan kategori akhir. Kombinasi ini memanfaatkan kekuatan kedua metode untuk meningkatkan akurasi klasifikasi. Hasil dari penelitian ini menunjukkan bahwa model *hybrid* yang dibangun berhasil mencapai akurasi sebesar 91.3%. Angka ini menandakan bahwa model tersebut efektif dalam melakukan klasifikasi kanker payudara dengan tingkat keakuratan yang signifikan. Pencapaian ini menunjukkan bahwa metode *hybrid* yang diterapkan dalam penelitian ini mampu mengatasi tantangan dalam klasifikasi kanker payudara dengan lebih baik dibandingkan metode tradisional.

Penelitian yang dilakukan oleh (Veena et. al, 2024) memfokuskan pada proses diagnosis glaucoma dengan memanfaatkan citra medis. Penelitian ini menggunakan model kombinasi dari *Recurrent Neural Network* (RNN) dan *Long Short-Term Memory* (LSTM) untuk meningkatkan akurasi dan efektivitas dalam klasifikasi glaucoma. Dalam penelitian ini, RNN dan LSTM digabungkan untuk memanfaatkan kekuatan keduanya dalam mengolah data sekuensial. RNN berfungsi untuk menangani data sekuensial yang mungkin terdapat dalam citra medis, sedangkan LSTM, yang merupakan varian dari RNN, ditambahkan untuk mengatasi masalah *vanishing gradient* dan untuk menangkap ketergantungan jangka panjang dalam data. Kombinasi kedua metode ini memungkinkan model untuk belajar dari pola temporal yang kompleks dalam citra, meningkatkan akurasi

klasifikasi. Hasil dari penelitian ini menunjukkan bahwa model RNN-LSTM yang dikembangkan mencapai akurasi pengujian sebesar 97.4%. Selain itu, model ini juga menunjukkan nilai spesifisitas (*specificity*) sebesar 97.9% dan sensitivitas (*sensitivity*) sebesar 97%. Spesifisitas mengukur kemampuan model untuk secara benar mengidentifikasi pasien yang tidak menderita *glaucoma*, sedangkan sensitivitas mengukur kemampuan model untuk mengidentifikasi pasien yang benar-benar menderita *glaucoma*.

Penelitian yang dilakukan oleh (Zamani et. al, 2021) membahas tentang proses klasifikasi emosi dengan memanfaatkan gabungan metode *Convolutional Neural Network* (CNN) dan *Recurrent Neural Network* (RNN). Fokus utama dari penelitian ini adalah untuk mengevaluasi performa kombinasi model CNN dan RNN dalam klasifikasi citra yang berkaitan dengan emosi. Dalam penelitian ini, dua jenis model gabungan diuji: 1D-CNN-GRU dan 1D-CNN-LSTM. Model 1D-CNN-GRU mengintegrasikan CNN dengan *Gated Recurrent Unit* (GRU), sementara model 1D-CNN-LSTM menggabungkan CNN dengan *Long Short-Term Memory* (LSTM). CNN digunakan untuk mengekstraksi fitur dari citra, sedangkan GRU dan LSTM, sebagai varian dari RNN, digunakan untuk memproses data sekuensial dan menangkap ketergantungan temporal dalam fitur yang diekstraksi. Hasil dari penelitian ini menunjukkan bahwa model 1D-CNN-GRU mencapai akurasi sebesar 96.3%, sementara model 1D-CNN-LSTM berhasil mencapai akurasi yang lebih tinggi, yaitu 97.8%. Akurasi ini menandakan bahwa model 1D-CNN-LSTM sedikit lebih efektif dalam melakukan klasifikasi emosi dibandingkan model 1D-CNN-GRU. Peningkatan akurasi ini menunjukkan bahwa LSTM mungkin lebih baik dalam menangkap pola temporal yang kompleks dalam data emosi dibandingkan GRU.

Tabel 2. 1. Penelitian Terkait

No	Penulis	Tahun	Penelitian	Metode	Hasil
1	S.	2024	Klasifikasi	CA-CNN	Hasil penelitian

	Manimurugan		konker kulit	dan RNN	menunjukkan bahwa model CA-CNN-RNN yang diusulkan berhasil mencapai kinerja yang mengesankan dengan akurasi pengujian sebesar 97.14%, presisi sebesar 96.49% dan f1-score sebesar 96.50%.
2	Azhar Imran, Jianqiang Li, Yan Pei, Faheem Akhtar, Tariq Mahmood dan Li Zhang	2021	Klasifikasi katarak	Kombinasi CNN dan RNN	Model yang dikembangkan dalam penelitian ini berhasil mencapai tingkat akurasi pengujian sebesar 97.39%. Angka ini menunjukkan peningkatan signifikan dibandingkan dengan hasil yang diperoleh dalam penelitian sebelumnya.
3	Rui Yan, Fei Ren, Zihao Wang, Lihua Wang, Tong Zhang, Yudong Liu, Xiaosong Rao, Chunhou Zheng dan Fa Zhang	2020	Klasifikasi kanker payudara	Kombinasi CNN dan RNN	Hasil dari penelitian ini menunjukkan bahwa model hybrid yang dibangun berhasil mencapai akurasi sebesar 91.3%. Angka ini menandakan bahwa model tersebut efektif dalam

					melakukan klasifikasi kanker payudara dengan tingkat keakuratan yang signifikan.
4	H. N. Veena, Kavita K. Patil, P. Vanajakshi, Anilkumar Ambore dan Naveen Chandra Gowda	2024	klasifikasi penyakit glaucoma	Kombinasi RNN dan LSTM	Hasil dari penelitian ini menunjukkan bahwa model RNN-LSTM yang dikembangkan mencapai akurasi pengujian sebesar 97.4%. Selain itu, model ini juga menunjukkan nilai spesifisitas (specificity) sebesar 97.9% dan sensitivitas (sensitivity) sebesar 97%.
5	Farhad Zamani and Retno Wulansari	2021	klasifikasi emosi	Kombinasi 1DCNN dan RNN	Hasil dari penelitian ini menunjukkan bahwa model 1D-CNN-GRU mencapai akurasi sebesar 96.3%, sementara model 1D-CNN-LSTM berhasil mencapai akurasi yang lebih tinggi, yaitu 97.8%.

BAB III METODOLOGI PENELITIAN

3.1 Instrumen Penelitian

Hasil dari pengembangan yang dilakukan dalam penelitian ini melibatkan pemanfaatan berbagai instrumen dan spesifikasi untuk mendukung proses penelitian. Ini mencakup perangkat keras, perangkat lunak, serta sistem operasi yang digunakan untuk mendukung pengembangan aplikasi. Berikut adalah rincian spesifikasi yang diterapkan dalam penelitian ini:

Tabel 3. 1. Tabel Instrumen Penelitian

Instrumen	Spesifikasi
<i>Inetgrated Processor</i>	11th Gen Intel(R) Core(TM) i7-11800H @ 2.30GHz (16 CPUs), ~2.3GHz
<i>Integrated Memory</i>	8 Gb
<i>Integrated SSD</i>	512 Gb
<i>Series</i>	Asus TUF Gaming FX06HC
<i>Microsoft Word Version</i>	2019
<i>Python Version (Installed)</i>	3.10

3.2 Pengumpulan Data

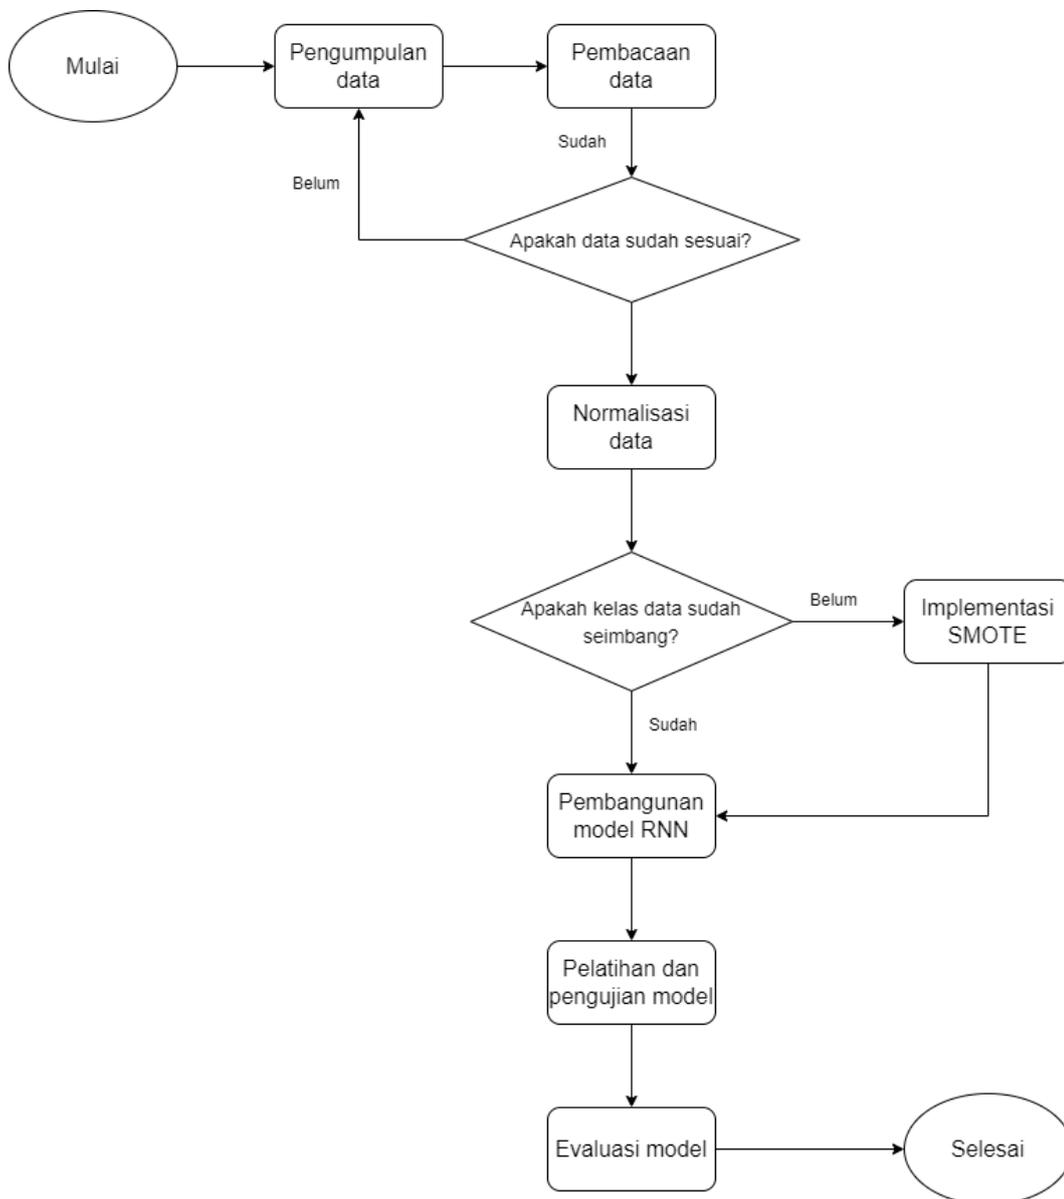
Dalam pengembangan model untuk penelitian ini, penting untuk memastikan bahwa model yang dikembangkan dapat mempelajari pola data secara efektif. Oleh karena itu, data yang digunakan untuk pelatihan dan pengujian model harus berkualitas dan representatif. Data yang digunakan dalam penelitian ini diperoleh dari RSUD Dr Pirngadi di kota Medan, sebuah rumah sakit yang dikenal memiliki fasilitas medis yang lengkap dan kredibel. RSUD Dr Pirngadi Medan, sebagai salah satu rumah sakit di kota Medan, yang Dimana rumah sakit ini menyediakan berbagai layanan medis, termasuk layanan radiologi. Data yang digunakan dalam penelitian ini berupa gambar citra *X-Ray* paru-paru pasien, yang dikumpulkan secara sistematis untuk keperluan diagnosis dan pemantauan kondisi kesehatan. Gambar-gambar ini mencerminkan kondisi paru-paru pasien dengan dua kategori utama: pasien yang tidak terinfeksi *pneumonia* (kategori normal) dan pasien yang terinfeksi *pneumonia*. Mengidentifikasi infeksi *pneumonia* pada tahap awal sangat penting untuk mencegah penyebaran lebih lanjut dan komplikasi yang lebih serius. Dengan adanya deteksi dini, langkah-langkah pencegahan dan pengobatan dapat diambil lebih awal, yang dapat meningkatkan prognosis pasien dan mengurangi risiko komplikasi. Oleh karena itu, visualisasi data seperti yang ditunjukkan pada Gambar 4, tidak hanya memberikan informasi tentang distribusi data dalam penelitian ini, tetapi juga menggarisbawahi pentingnya identifikasi dan diagnosis dini terhadap infeksi *pneumonia*. Ini menekankan kebutuhan untuk menggunakan teknologi diagnostik canggih dalam mengidentifikasi kondisi patologis dan memastikan penanganan yang tepat untuk menjaga kesehatan paru-paru pasien.

3.3 Metode yang Diusulkan

Mengingat perlunya diagnosis lebih awal untuk mengidentifikasi penyakit *pneumonia* lebih awal dan mengurangi risiko yang terjadi, maka diperlukan suatu sistem

yang dapat melakukan prediksi dan identifikasi yang cepat dan akurat. Oleh karena itu, pada penelitian ini mengusulkan untuk membangun model klasifikasi penyakit *pneumonia* berdasarkan citra *X-Ray* dengan menggunakan metode *deep learning*. Dalam penelitian ini metode klasifikasi yang digunakan yaitu dengan menggunakan metode *Recurrent Neural Network* (RNN). Setelah data dikumpulkan, maka Langkah selanjutnya yaitu melakukan proses *preprocessing* data atau pemrosesan data sehingga siap digunakan untuk melatih dan menguji model yang dibangun. Dalam penelitian ini proses *preprocessing* yang dilakukan yaitu menyeimbangkan kelas data. Tahap ini dilakukan karena dataset yang dikumpulkan memiliki kesenjangan jumlah antara kelas *pneumonia* dan kelas normal, sehingga hal tersebut dapat menyebabkan bias pada data dan model tidak bisa mempelajari pola dari data dengan maksimal. Oleh karena itu, pada penelitian ini proses penyeimbangan jumlah data akan menggunakan metode *Syntetic Minority Over Sampling* (SMOTE). Metode SMOTE bekerja dengan melakukan generate data sintetis pada kelas data minoritas sehingga bisa berjumlah sama atau setidaknya mendekati data mayoritas. Sehingga dengan adanya metode ini diharapkan model yang dibangun dapat mempelajari pola data dengan maksimal. Dalam penelitian ini, proses klasifikasi akan menggunakan metode *Recurrent Neural Network*. RNN dipilih karena kemampuannya untuk menangani data yang bersifat sekuensial atau temporal. Meskipun citra *X-Ray* umumnya dianggap data statis, RNN dapat menangkap pola-pola temporal dan hubungan jangka panjang yang mungkin tersembunyi dalam data citra. RNN dapat membantu model memahami struktur data yang kompleks dan membuat prediksi yang lebih akurat dengan mempertimbangkan urutan dan hubungan antar fitur. Sehingga, dengan dibangunnya model tersebut diharapkan dapat membantu proses identifikasi dan diagnosa penyakit *pneumonia* lebih cepat serta bisa diambil tindakan penanganan secepatnya agar tidak parah. Berdasarkan pembahasan yang telah dilakukan, maka untuk mencapai tujuan yaitu membangun model klasifikasi penyakit *pneumonia*, maka diperlukan sebuah alur

proses yang jelas. Untuk alur proses penelitian dalam membangun sistem diagnosa penyakit *pneumonia* diberikan pada gambar 3.1.



Gambar 3. 1. Alur Penelitian

Gambar 3.1 menunjukkan alur proses penelitian yang dilakukan. Berdasarkan gambar 5, bisa dijabarkan alur penelitian sebagai berikut:

1. Hal pertama yang dilakukan yaitu pengumpulan data penelitian, yang Dimana pada penelitian ini, data didapatkan dari RSUD Dr Pirngadi Medan, yang Dimana

berupa data paru paru hasil scan *X-Ray* pada rumah sakit tersebut, yang Dimana berjumlah sebanyak 5840 data citra dengan ekstensi .jpeg dan memiliki kelas data yaitu normal dan *pneumonia*.

2. Selanjutnya, setelah dilakukan proses pengumpulan data, maka dilakukan proses pembacaan data dan pengecekan data apakah data yang didapatkan sudah sesuai sudah atau belum, apabila data sudah sesuai, maka dapat melanjutkan pada Langkah selanjutnya dan apabila belum melakukan pengumpulan data ulang.
3. Setelah data dipastikan sesuai, maka selanjutnya melakukan proses normalisasi data. Dalam tahapan ini, data citra yang didapatkan dilakukan proses normalisasi dan *reshape* data sehingga menjadi ukuran *pixel* antara 0 hingga 255 serta ukuran citra sebesar 150 x 150 *pixel*. Hal ini dilakukan dengan tujuan agar model yang dibangun dapat memproses data secara general dan memiliki waktu komputasi yang cepat.
4. Setelah dilakukan proses normalisasi data, maka dapat dilakukan pengecekan apakah data yang digunakan memiliki kelas yang seimbang, apabila data memiliki kelas yang seimbang maka dapat langsung menuju Langkah Pembangunan model, namun apabila kelas data tidak seimbang, maka dilakukan proses *generate* data *syntetic* menggunakan SMOTE. Karena pada *dataset* yang didapatkan memiliki persebaran data yang tidak merata, maka dilakukan proses implementasi SMOTE.
5. Karena *dataset* yang digunakan pada penelitian ini memiliki jumlah yang tidak seimbang, maka dilakukan proses implementasi metode SMOTE untuk *generate* *syntetic* data pada data minoritas sehingga memiliki jumlah yang sama atau mungkin mendekati jumlah data pada kelas mayoritas. Sehingga, dengan hal tersebut, pelatihan model dapat baik dan model tidak bias dalam mempelajari data.

6. Setelah dilakukan pemrosesan data, maka selanjutnya dilakukan proses Pembangunan model *deep learning* yang dibangun. Dalam penelitian ini, model yang digunakan yaitu merupakan model *Reccurent Neural Network* (RNN), dengan layer layer yang digunakan diberikan pada gambar 3.2.

```

Model: "sequential"
-----
Layer (type)      Output Shape      Param #
-----
reshape (Reshape) (None, 150, 150)  0
-----
simple_rnn (SimpleRNN) (None, 128)      35840
-----
dense (Dense)      (None, 64)        8256
-----
dropout (Dropout) (None, 64)        0
-----
dense_1 (Dense)    (None, 2)         130
-----
Total params: 44,226
Trainable params: 44,226
Non-trainable params: 0
-----

```

Gambar 3. 2. Layer RNN yang digunakan

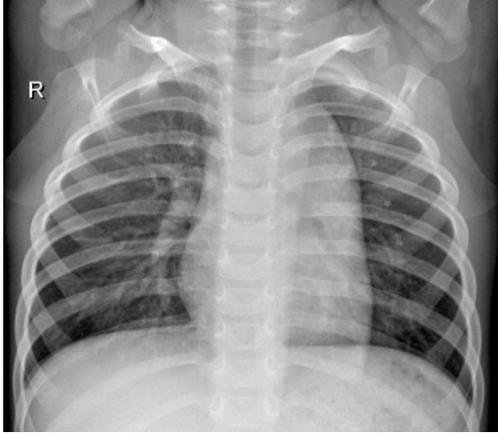
7. Setelah dilakukan proses Pembangunan model RNN, maka dapat dilakukan proses pelatihan dan pengujian model. Pelatihan model bertujuan agar model yang dibangun dapat mempelajari pola dari data, serta pengujian model bertujuan agar model yang dibangun dapat di evaluasi bagaimana performa dalam proses prediksi data.
8. Selanjutnya, setelah melakukan proses pengujian model, maka dapat melakukan proses evaluasi performa model dengan menggunakan nilai nilai *confusion matrix* yaitu akurasi, *presisi*, *recall* dan *f1-score*.

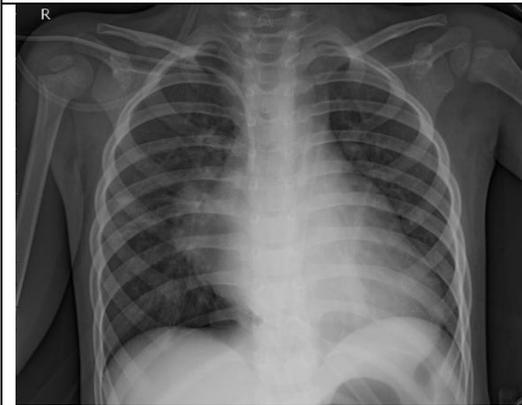
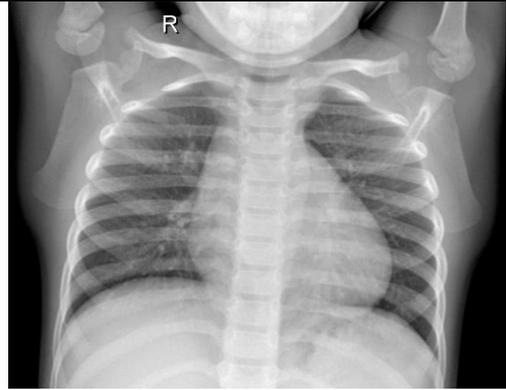
BAB IV HASIL DAN PEMBAHASAN

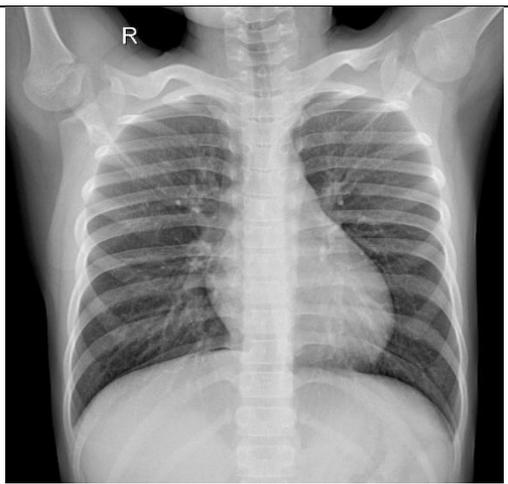
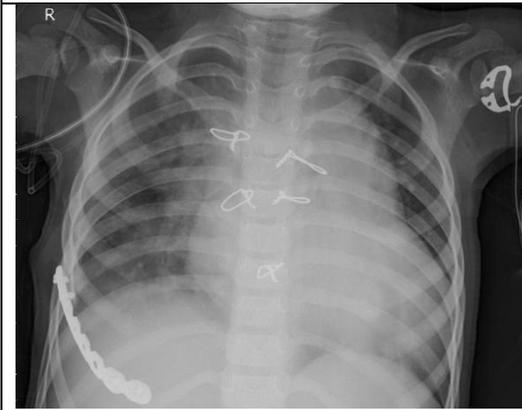
4.1 Analisis Data

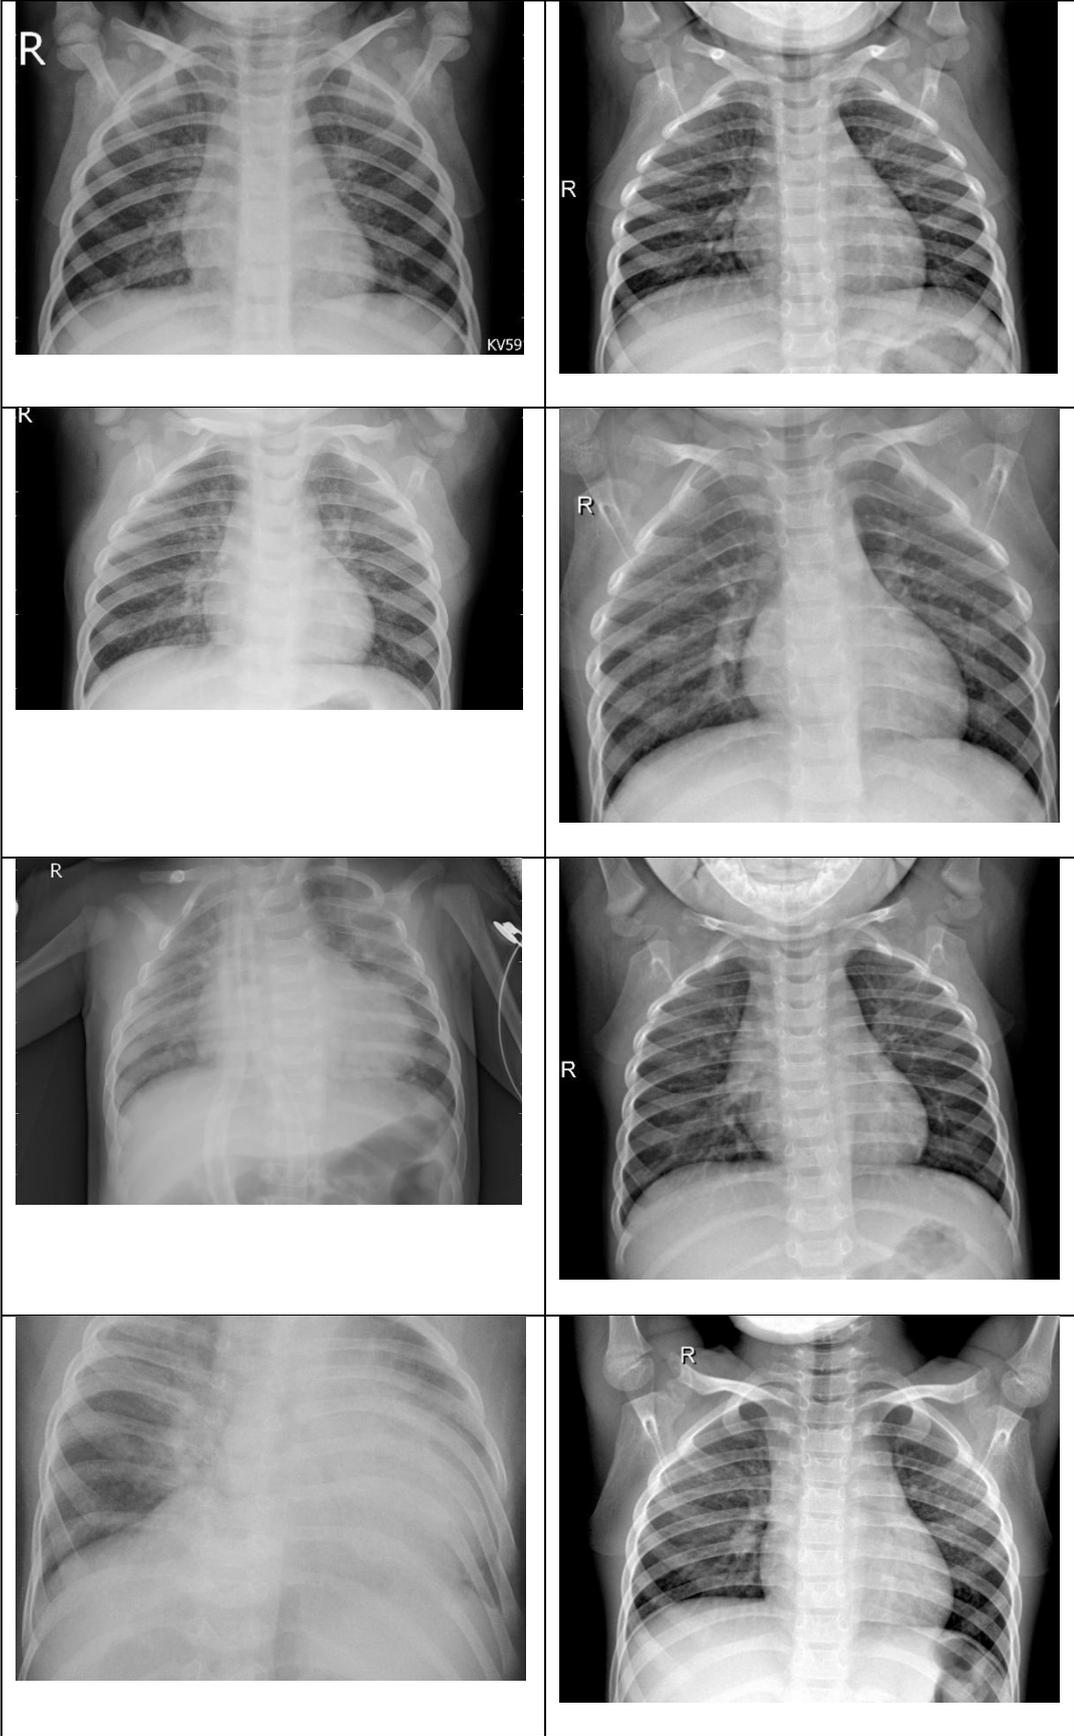
Dalam penelitian ini, *dataset* yang digunakan merupakan *dataset* yang diperoleh dari pengumpulan data pada RSUD Dr Pirngadi di kota Medan. Berdasarkan hasil yang pengumpulan data *Dataset* yang diperoleh terdiri dari total 5.840 gambar citra *X-Ray*. Dari jumlah ini, terdapat 4.265 gambar citra yang termasuk dalam kategori *pneumonia*, menunjukkan kasus di mana pasien terdiagnosis dengan *pneumonia*. Sementara itu, 1.575 gambar citra termasuk dalam kategori normal, yang menunjukkan bahwa pasien tidak mengalami infeksi *pneumonia*. Data ini telah dikumpulkan secara cermat untuk memastikan keberagaman dan representativitas, mencakup berbagai kondisi dan karakteristik citra paru-paru dari pasien yang berbeda. Proses pengumpulan data melibatkan seleksi dan anotasi yang teliti untuk memastikan bahwa gambar-gambar tersebut dapat digunakan untuk tujuan pelatihan model pembelajaran mesin. Untuk melatih model, *dataset* ini dibagi menjadi dua bagian. Sebanyak 5.216 gambar citra digunakan untuk proses pelatihan, terdiri dari 3.875 gambar pada kategori *pneumonia* dan 1.341 gambar pada kategori normal. Pembagian ini dirancang untuk memberikan model cukup data untuk belajar dari berbagai contoh dan mengembangkan kemampuan deteksi yang akurat. Sisanya, yaitu 624 gambar citra, digunakan untuk pengujian model. Data pengujian terdiri dari 390 gambar pada kategori *pneumonia* dan 234 gambar pada kategori normal, dan bertujuan untuk menilai kinerja model pada data yang belum pernah dilihat sebelumnya. Pembagian dan penggunaan data ini dirancang untuk memastikan bahwa model dapat belajar secara efektif dari data pelatihan dan diuji dengan data yang representatif. Visualisasi dari data yang digunakan pada penelitian ini diberikan pada Tabel 4.1.

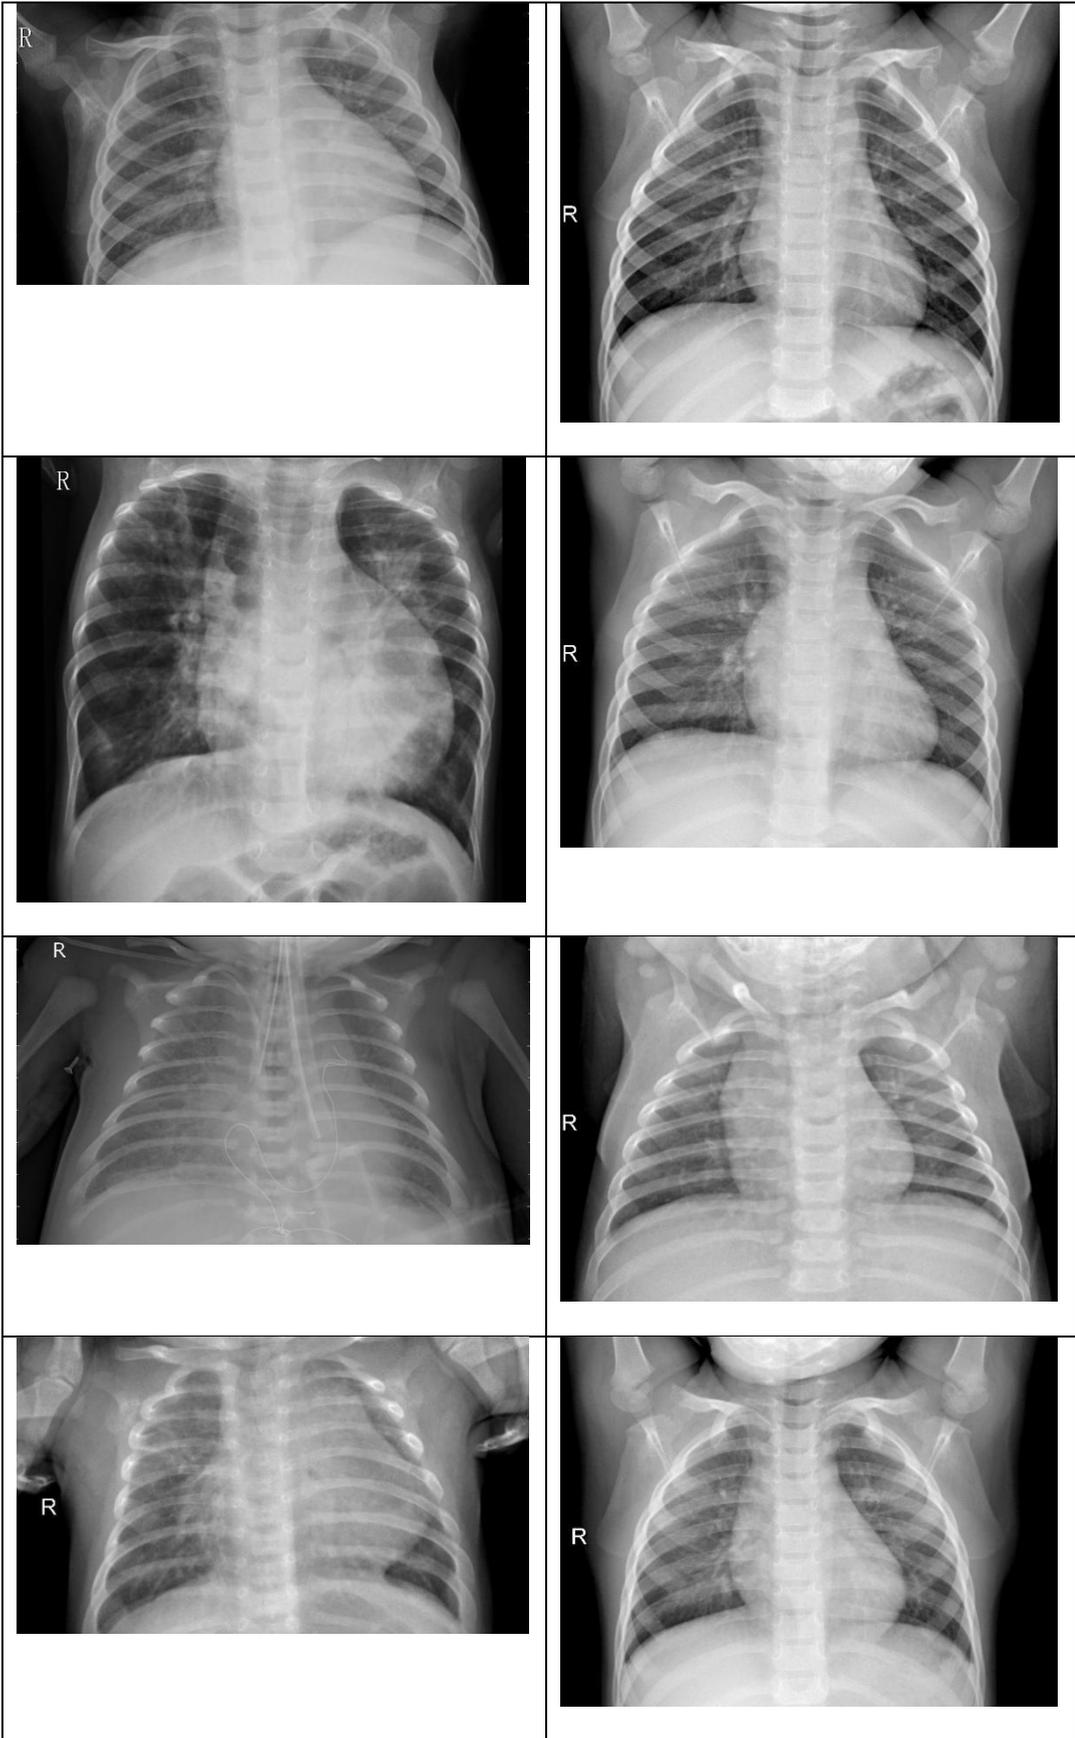
Tabel 4. 1. Visualisasi kelas dataset

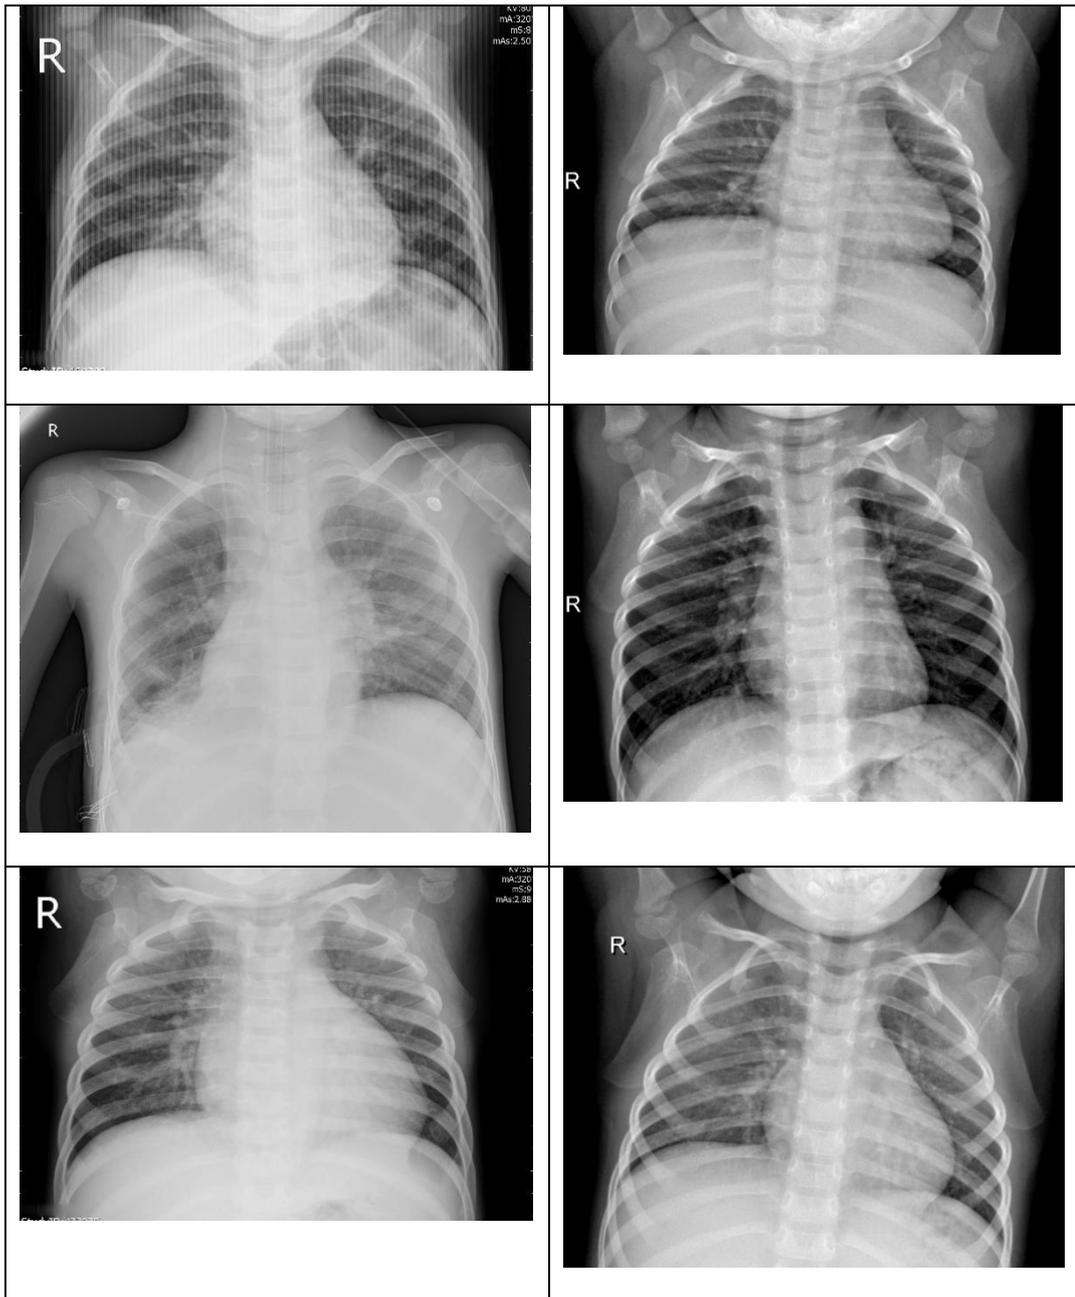
Pneumonia	Normal
	
	
	





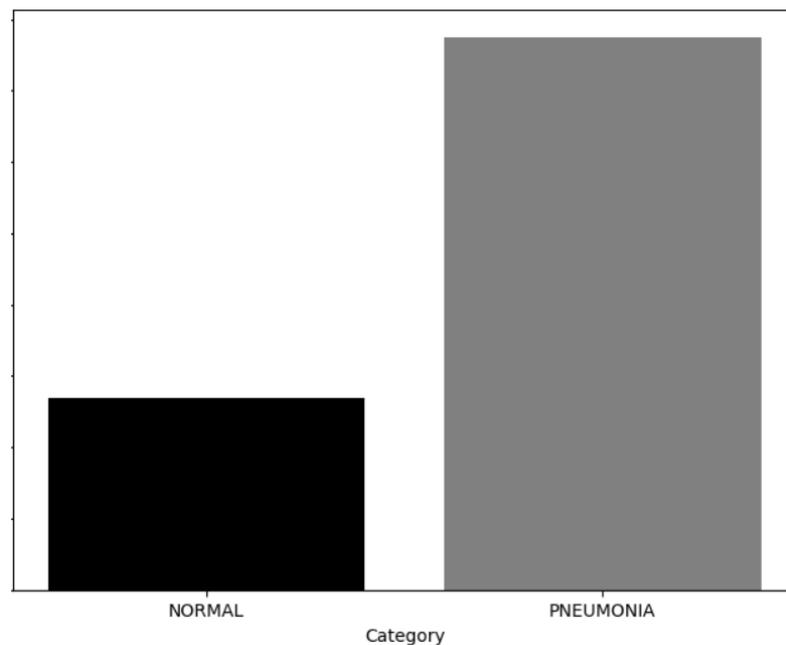






Tabel 4.1 menunjukkan visualisasi data yang digunakan dalam penelitian ini, memberikan gambaran yang mendetail mengenai karakteristik citra *X-Ray* paru-paru yang digunakan untuk analisis. Berdasarkan tabel yang diberikan mengenai perbandingan data kelas *pneumonia* dan normal, dapat dilihat bahwa pada gambar tersebut, tampak jelas perbedaan yang signifikan antara citra paru-paru yang menunjukkan infeksi *pneumonia* dan citra paru-paru yang sehat (normal). Dalam gambar 6, citra paru-paru yang terinfeksi *pneumonia* menunjukkan adanya indikasi visual yang khas, yaitu semacam kabut atau

area putih yang menyebar pada gambar. Fenomena ini terjadi karena adanya infeksi oleh jamur atau virus, yang menyebabkan infiltrasi atau penumpukan cairan serta perubahan pada jaringan paru-paru. Kabut atau area putih ini sering kali menunjukkan kerusakan pada jaringan paru-paru, yang merupakan tanda khas dari *pneumonia*. Infeksi ini dapat disebabkan oleh berbagai patogen, seperti bakteri, virus, atau jamur, dan dapat mengakibatkan penurunan fungsi paru-paru dan komplikasi serius jika tidak ditangani dengan cepat. Sebaliknya, pada citra paru-paru yang normal, terlihat kondisi paru-paru yang sehat tanpa adanya indikasi infeksi atau perubahan patologis. Citra ini menunjukkan pola dan tekstur paru-paru yang bersih dan teratur, tanpa adanya area kabut atau penumpukan yang mencurigakan. Kesehatan paru-paru dapat dilihat dari keberadaan struktur jaringan paru yang jelas dan bebas dari tanda-tanda infeksi. Berdasarkan pemaparan yang dilakukan, dapat diketahui bahwa data yang digunakan memiliki jumlah data pada setiap kelas yang tidak seimbang. Untuk visualisasi persebaran data diberikan pada gambar 4.1.



Gambar 4. 1. Persebaran data awal

Gambar 4.1 menunjukkan persebaran data yang berhasil dikumpulkan. Berdasarkan persebaran tersebut, maka dapat dilihat bahwa model yang dibangun memiliki ketidakseimbangan data pada kelas normal dan *pneumonia*. Hal tersebut tidak baik bagi model untuk belajar mengenali pola dari data, sehingga model tidak maksimal mempelajari pola dari data dan mengakibatkan bias serta dapat mengurangi performa model dalam melakukan proses klasifikasi. Sehingga, untuk mengatasi hal tersebut, pada penelitian ini dilakukan proses penyeimbangan kelas data dengan menggunakan metode *Syntetic Minority Over Sampling* atau SMOTE yang dimana melakukan generate data sintetis pada data minoritas sehingga dapat memiliki jumlah data yang sama atau mendekati jumlah pada data mayoritas. Untuk hasil perbandingan data asli dengan data sintetis diberikan pada tabel 4.2 berikut.

Tabel 4. 2. Visualisasi data hasil SMOTE

Kelas	Citra Asli	Citra Sintetis
Normal		
Normal		

Normal		
Normal		
Normal		
Normal		
Normal		

Normal		
Normal		
Normal		
Normal		
Normal		

Normal		
Normal		
Normal		
Normal		
Normal		

Normal		
Normal		
Normal		
<i>Pneumonia</i>		
<i>Pneumonia</i>		

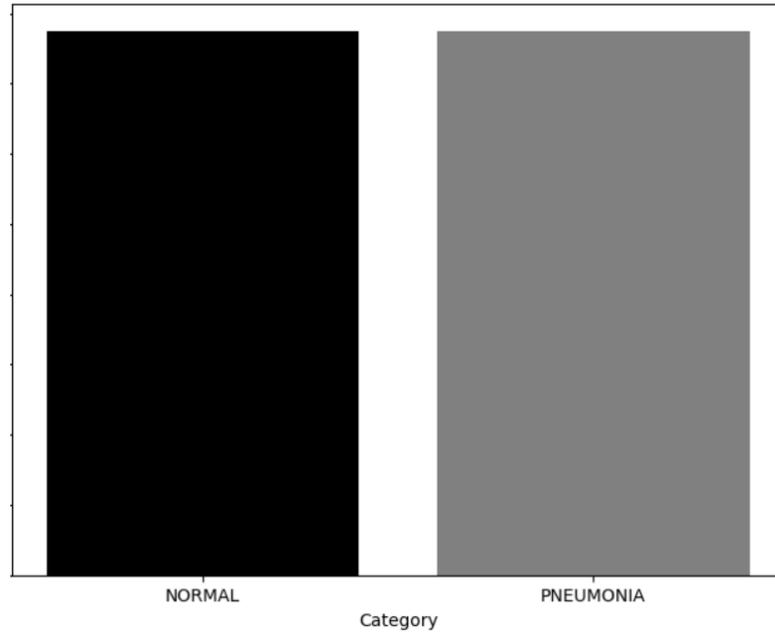
<i>Pneumonia</i>		
<i>Pneumonia</i>		
<i>Pneumonia</i>		
<i>Pneumonia</i>		
<i>Pneumonia</i>		

<i>Pneumonia</i>		
<i>Pneumonia</i>		
<i>Pneumonia</i>		
<i>Pneumonia</i>		
<i>Pneumonia</i>		

<i>Pneumonia</i>		
<i>Pneumonia</i>		
<i>Pneumonia</i>		
<i>Pneumonia</i>		
<i>Pneumonia</i>		

<i>Pneumonia</i>		
<i>Pneumonia</i>		
<i>Pneumonia</i>		

Tabel 4.2 menunjukkan data hasil implementasi proses *Syntetic Minority Over Sampling (SMOTE)*. Dapat dilihat pada tabel 4.2, metode SMOTE berhasil untuk memunculkan gambar baru yang mirip sehingga bisa menambah variasi data dan meningkatkan kinerja model dalam melakukan proses pembelajaran pola dari data. Setelah dilakukan proses implementasi data, maka jumlah kelas data dapat seimbang. Untuk hasil persebaran data dari implementasi proses SMOTE diberikan pada gambar 4.2.

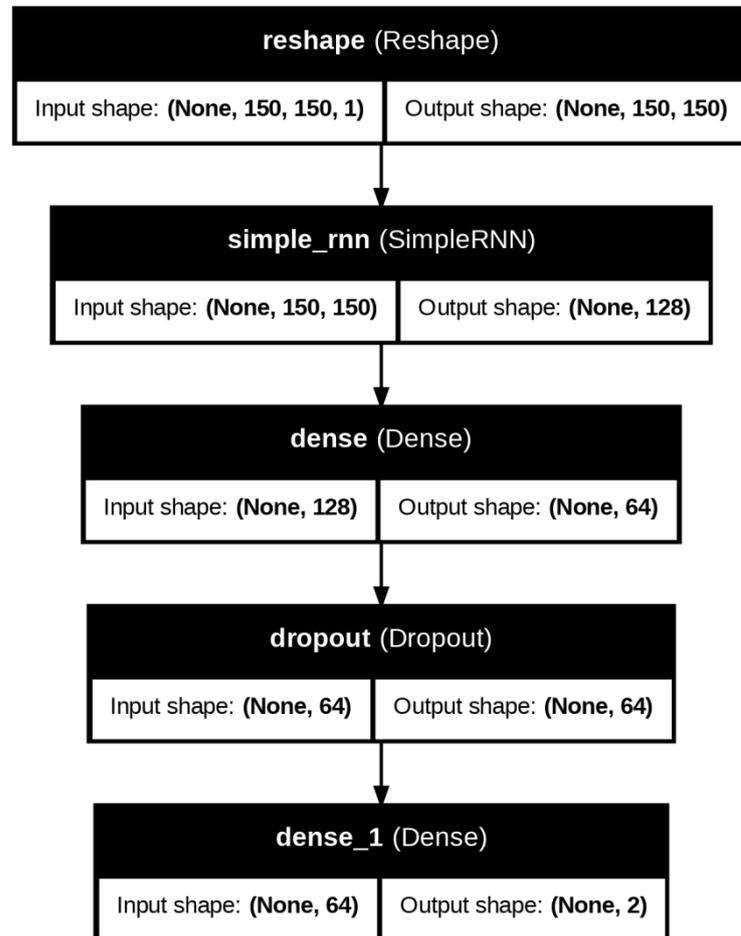


Gambar 4. 2. Persebaran data hasil SMOTE

Gambar 4.2 menunjukkan persebaran data setelah dilakukan proses SMOTE. Dapat dilihat pada gambar 4.2, setelah dilakukan proses implementasi SMOTE, persebaran baik pada data kelas normal dan *pneumonia* dapat seimbang dan dengan hal tersebut diharapkan bahwa model bisa mempelajari pola dari data dengan maksimal dan tidak bias serta dapat menghasilkan akurasi yang optimal.

4.2 Analisis Layer RNN

Dalam penelitian ini, proses klasifikasi akan dilakukan menggunakan algoritma *Reccurent Neural Network*. Untuk layer layer yang digunakan diberikan pada gambar 4.3.



Gambar 4. 3. Layer penelitian

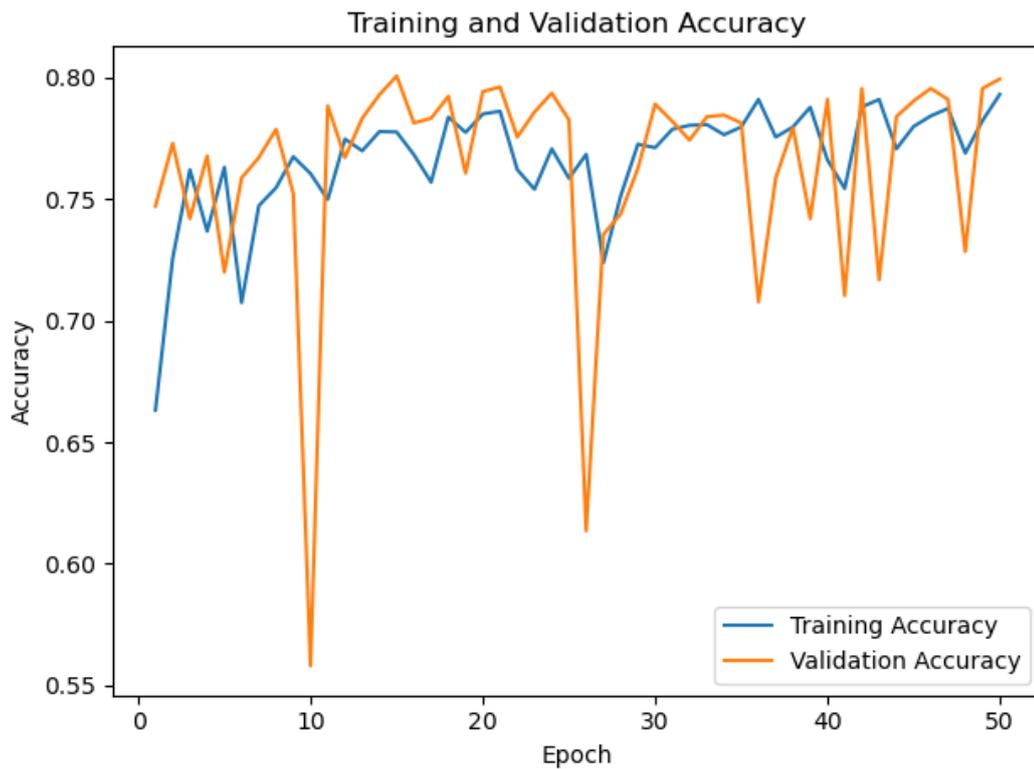
Gambar 4.3 menunjukkan layer yang digunakan untuk melakukan proses klasifikasi *pneumonia* berdasarkan citra *X-Ray*. Dapat dilihat pada gambar 4.3, Pada bagian awal, terdapat layer Reshape yang bertugas mengubah dimensi input dari (150, 150, 1) menjadi (150, 150), dengan tujuan menyesuaikan bentuk data agar sesuai dengan input yang diperlukan oleh layer berikutnya. Layer ini menerima citra *X-ray* berukuran 150x150 *pixel* dengan satu *channel* (*grayscale*), yang merupakan format umum untuk citra medis. Selanjutnya, model menggunakan layer *SimpleRNN* (*Simple Recurrent Neural Network*), yang berfungsi untuk menangkap pola atau dependensi temporal dalam data. Meskipun umumnya RNN lebih sering digunakan untuk data sekuensial seperti teks atau sinyal waktu, penggunaannya dalam model klasifikasi citra di sini bisa dimaksudkan

untuk mengeksplorasi dependensi antara piksel citra dari berbagai arah atau urutan tertentu. Layer ini menerima input dengan dimensi (150, 150) dan menghasilkan *output* dengan dimensi (None, 128), di mana 128 adalah jumlah unit yang digunakan dalam RNN.

Setelah itu, *layer Dense* digunakan untuk mengurangi dimensi *output* dari RNN menjadi 64 neuron. *Layer Dense* ini merupakan *fully connected layer* yang mengubah data ke dalam bentuk yang lebih abstrak dan membantu jaringan saraf dalam menentukan fitur yang relevan dari citra *X-ray* yang akan digunakan dalam proses klasifikasi. Model kemudian menggunakan *Dropout layer* yang berfungsi untuk mengurangi *overfitting* dengan secara acak menonaktifkan beberapa neuron selama proses pelatihan. *Dropout* membantu jaringan saraf agar tidak terlalu bergantung pada *neuron* tertentu, sehingga model menjadi lebih generalis pada data yang belum pernah dilihat sebelumnya. Pada tahap akhir, model menggunakan *layer Dense* lagi untuk melakukan klasifikasi akhir. *Output* dari layer sebelumnya yang terdiri dari 64 *neuron* diproyeksikan menjadi 2 *output neuron*, yang mengindikasikan bahwa ini adalah tugas klasifikasi biner. Dalam kasus ini, dua *output* tersebut mungkin merepresentasikan dua kelas, yaitu "*pneumonia*" dan "*tidak pneumonia*". Model ini dioptimalkan untuk memprediksi apakah citra *X-ray* pasien menunjukkan tanda-tanda *pneumonia* atau tidak. Dengan arsitektur seperti ini, model *neural network* dapat melakukan ekstraksi fitur secara mendalam melalui beberapa lapisan pemrosesan *non-linear*, sebelum akhirnya melakukan klasifikasi untuk mendeteksi adanya *pneumonia*. Bagian selanjutnya dalam pembahasan ini mungkin akan berfokus pada hasil eksperimen, evaluasi kinerja model, serta perbandingan dengan metode klasifikasi lainnya untuk menunjukkan efektivitas penggunaan arsitektur ini dalam deteksi *pneumonia* berbasis citra *X-ray* yang diinputkan.

4.3 Hasil Pengujian

Setelah dilakukan proses Pembangunan dan pemrosesan data untuk model belajar mengenali pola dari data serta evaluasi model menggunakan SMOTE, maka selanjutnya dapat dilakukan proses pengujian model. Dalam penelitian ini, model *Reccurent Neural Network* yang dibangun dilatih menggunakan nilai *epoch* pelatihan sebanyak 50, nilai *batch size* yaitu 16 dan *optimizer* menggunakan *adam*. Proses pelatihan dilakukan dengan tujuan untuk mengoptimalkan kemampuan model dalam mengenali pola-pola kompleks pada data citra *X-ray*. Penggunaan nilai *epoch* sebanyak 50 bertujuan untuk memberikan waktu yang cukup bagi model untuk belajar dan mengadaptasi parameter-parameter yang dimilikinya secara bertahap, sehingga dapat meminimalkan kesalahan prediksi pada setiap iterasi. Jumlah *batch size* yang ditetapkan sebesar 16 memungkinkan model untuk memperbarui bobotnya setelah melihat setiap batch data, yang pada akhirnya membantu dalam stabilisasi proses pembelajaran, serta mencegah *overfitting* dengan pembaruan yang lebih terkontrol. *Optimizer adam* dipilih karena memiliki kemampuan adaptif dalam mengatur laju pembelajaran, yang sangat efektif dalam mempercepat konvergensi model dengan tetap menjaga kestabilan, terutama dalam menangani data dengan distribusi yang tidak merata seperti dalam kasus ini. Kombinasi parameter-parameter tersebut dirancang untuk memastikan bahwa model dapat belajar dengan efektif dari data yang disediakan, sehingga menghasilkan prediksi yang akurat dan handal dalam klasifikasi penyakit *pneumonia*. Setelah dilakukan proses pelatihan model, mendapatkan grafik akurasi pelatihan dan validasi yang diberikan pada gambar 4.4.

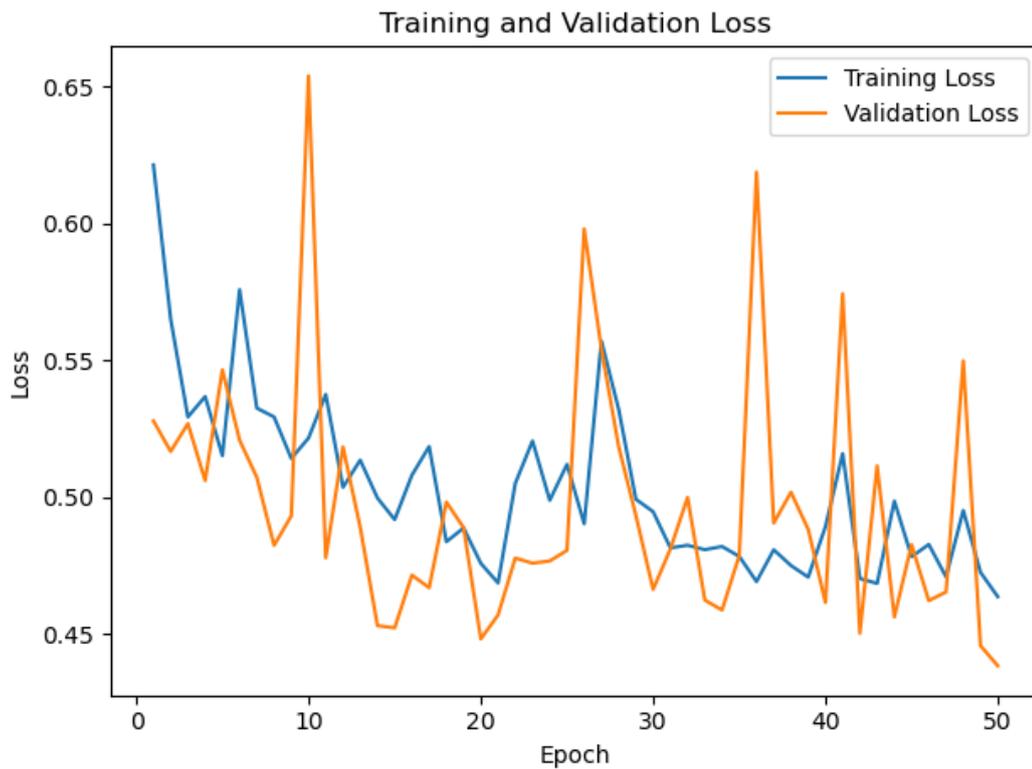


Gambar 4. 4. Hasil proses pelatihan dan validasi

Gambar 4.4 memperlihatkan grafik yang menggambarkan perkembangan akurasi selama proses pelatihan dan validasi model *Recurrent Neural Network* (RNN) yang telah dibangun. Grafik ini menampilkan dua kurva utama, yaitu kurva akurasi pelatihan dan kurva akurasi validasi, yang masing-masing menunjukkan bagaimana model belajar dari data pelatihan serta bagaimana kinerjanya dievaluasi pada data yang tidak dilihat sebelumnya (data validasi). Pada proses pelatihan, model RNN berhasil mencapai akurasi pelatihan sebesar 79.31%. Angka ini mencerminkan seberapa baik model dapat mengenali pola dan fitur yang terdapat dalam *dataset* pelatihan. Dengan akurasi pelatihan yang relatif tinggi, hal ini menunjukkan bahwa model telah mampu memahami dan menyesuaikan diri dengan data pelatihan yang disediakan.

Di sisi lain, akurasi validasi yang dicapai sebesar 79.94% memberikan indikasi tentang kinerja model ketika dihadapkan pada data baru yang tidak pernah dilihat selama proses pelatihan. Akurasi validasi yang mendekati akurasi pelatihan menunjukkan bahwa model memiliki generalisasi yang baik, yaitu kemampuan untuk menerapkan apa yang

telah dipelajari dari data pelatihan ke data baru dengan tingkat akurasi yang konsisten. Perbedaan yang kecil antara akurasi pelatihan dan validasi ini juga mengindikasikan bahwa model tidak mengalami *overfitting* yang signifikan, di mana *overfitting* terjadi ketika model terlalu menyesuaikan diri dengan data pelatihan dan tidak dapat bekerja dengan baik pada data validasi. Oleh karena itu, dengan akurasi pelatihan dan validasi yang hampir setara, kita dapat menyimpulkan bahwa model RNN ini mampu memberikan prediksi yang handal dan memiliki kemampuan generalisasi yang kuat, sehingga layak digunakan dalam klasifikasi penyakit *pneumonia* pada kasus penelitian ini. Gambar 10 dengan jelas mendokumentasikan kinerja model sepanjang proses pelatihan dan validasi, sehingga memberikan gambaran visual yang komprehensif tentang bagaimana model berkembang dan belajar seiring waktu. Selain grafik akurasi, pada proses pelatihan dan validasi juga dihasilkan grafik *loss* yang dialami model. Untuk grafik *loss* yang dihasilkan model diberikan pada gambar 4.5.



Gambar 4. 5. Hasil loss pelatihan dan validasi

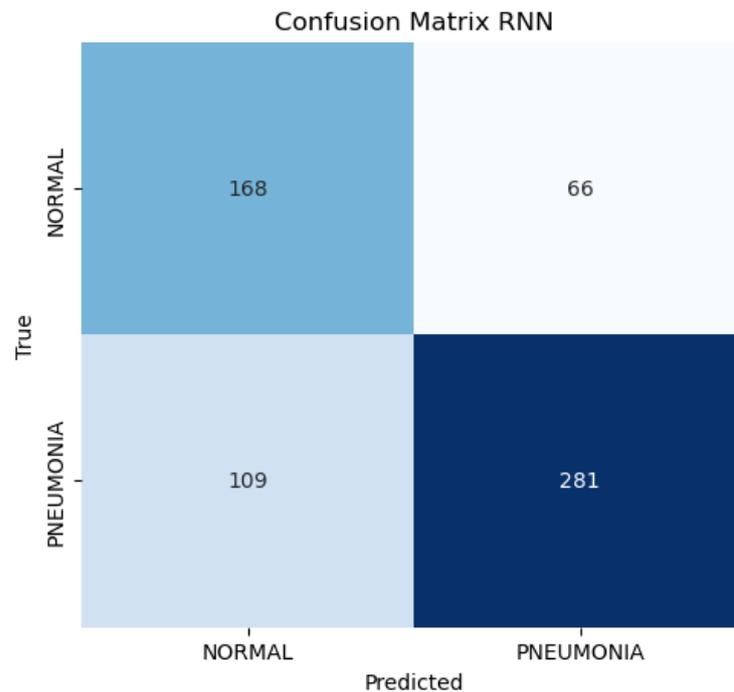
Gambar 4.5 menunjukkan grafik *loss* yang dihasilkan dari proses pelatihan dan validasi model *Recurrent Neural Network* (RNN) yang telah dibangun. Dalam proses pelatihan dan validasi, model RNN mendapatkan nilai *loss* sebesar 0.4638 pada saat pelatihan dan nilai *loss* sebesar 0.4386 pada saat validasi model. Gambar 11 menampilkan grafik yang menggambarkan perkembangan *loss* selama proses pelatihan dan validasi model *Recurrent Neural Network* (RNN) yang telah dibangun. Grafik ini penting karena *loss* merupakan metrik yang digunakan untuk mengukur seberapa baik model memprediksi *output* yang benar. Nilai *loss* yang lebih rendah menunjukkan bahwa prediksi model lebih mendekati nilai sebenarnya. Selama proses pelatihan, model RNN menghasilkan nilai *loss* sebesar 0.4638. Nilai ini menggambarkan rata-rata kesalahan yang dibuat oleh model saat mencoba memprediksi *output* berdasarkan data pelatihan. Nilai *loss* yang cukup rendah ini mengindikasikan bahwa model telah berhasil

mempelajari pola-pola yang ada dalam data pelatihan dengan cukup baik, sehingga kesalahan prediksi dapat diminimalisir.

Pada saat proses validasi, model RNN memperoleh nilai *loss* sebesar 0.4386, yang sedikit lebih rendah dibandingkan dengan nilai *loss* pada pelatihan. Nilai *loss* validasi ini memberikan gambaran tentang seberapa baik model dapat menerapkan apa yang telah dipelajarinya dari data pelatihan ke data baru yang tidak pernah dilihat sebelumnya. Penurunan nilai *loss* pada validasi dibandingkan dengan pelatihan menunjukkan bahwa model tidak hanya cocok dengan data pelatihan, tetapi juga memiliki kemampuan generalisasi yang baik ketika dihadapkan pada data yang berbeda. Perbedaan kecil antara nilai *loss* pelatihan dan validasi mengindikasikan bahwa model tidak mengalami *overfitting* secara signifikan, yaitu kondisi di mana model terlalu menyesuaikan diri dengan data pelatihan sehingga tidak mampu memprediksi data baru dengan baik. Sebaliknya, konsistensi antara kedua nilai *loss* ini menunjukkan bahwa model memiliki performa yang stabil dan dapat diandalkan. Grafik *loss* yang ditunjukkan pada Gambar 11 memberikan visualisasi yang jelas tentang bagaimana kesalahan model menurun seiring dengan proses pelatihan dan validasi. Ini juga membantu dalam memahami bagaimana model belajar dan seberapa efektif model dalam mengurangi kesalahan prediksi selama iterasi yang berlangsung. Hasil yang ditunjukkan oleh grafik ini memperkuat keyakinan bahwa model RNN yang dibangun mampu melakukan klasifikasi *pneumonia* dengan tingkat kesalahan yang rendah, baik dalam konteks pelatihan maupun validasi.

Setelah proses pelatihan model selesai, hasil yang diperoleh menunjukkan bahwa model memiliki kemampuan yang baik dalam mengklasifikasikan penyakit *pneumonia* berdasarkan data yang diberikan. Namun, untuk memastikan bahwa model ini benar-benar dapat diandalkan dan mampu memberikan prediksi yang akurat pada data yang belum pernah dilihat sebelumnya, perlu dilakukan pengujian model lebih lanjut. Proses pengujian model ini dilakukan dengan menggunakan *dataset* yang berbeda dari yang digunakan selama pelatihan, bertujuan untuk mengevaluasi kinerja model dalam kondisi

yang lebih realistis dan menguji kemampuannya dalam generalisasi. Salah satu cara utama untuk menilai performa model pada tahap pengujian adalah dengan menggunakan *confusion matrix*. Untuk hasil *confusion matrix* setelah dilakukan proses pengujian model diberikan pada gambar 4.6.



Gambar 4. 6. Hasil *confusion matrix* pengujian

Gambar 4.6 menunjukkan *confusion matrix* yang didapatkan setelah dilakukan proses pengujian model *Recurrent Neural Network* (RNN) yang telah dilatih sebelumnya. Dapat dilihat pada Gambar 4.6, model ini memiliki kinerja yang beragam dalam mengklasifikasikan dua kategori utama, yaitu "Normal" dan "Pneumonia." *Confusion matrix* ini terdiri dari empat bagian yang mencerminkan hasil prediksi model: *True Positives* (TP), *True Negatives* (TN), *False Positives* (FP), dan *False Negatives* (FN). Pada bagian "Normal," model berhasil mengidentifikasi 168 kasus dengan benar (*True Negatives*), namun terdapat 66 kasus di mana model salah mengklasifikasikan pasien normal sebagai *pneumonia* (*False Positives*). Ini menunjukkan bahwa meskipun model

cukup andal dalam mengidentifikasi kondisi normal, masih ada jumlah kesalahan yang signifikan di mana pasien yang sehat terdeteksi secara keliru sebagai penderita *pneumonia*.

Untuk kategori "*Pneumonia*," model mampu mengidentifikasi 281 kasus dengan benar (*True Positives*), namun terdapat 109 kasus di mana model gagal mendeteksi *pneumonia* dan mengklasifikasikan pasien tersebut sebagai normal (*False Negatives*). Berdasarkan hasil yang didapatkan, terlihat bahwa model *Recurrent Neural Network* (RNN) memiliki kinerja yang lebih baik dalam mendeteksi kasus *pneumonia* dibandingkan dengan mengidentifikasi kondisi normal. Hal ini dapat dilihat dari jumlah *True Positives* yang lebih tinggi dibandingkan dengan *True Negatives*, serta jumlah *False Positives* yang lebih rendah dibandingkan dengan *False Negatives*. Dengan kata lain, model ini lebih cenderung untuk mendeteksi pasien yang sebenarnya menderita *pneumonia*, meskipun masih ada beberapa kasus di mana model gagal mengenali pasien yang tidak menderita penyakit ini. Meskipun model memiliki performa yang lebih baik dalam mendeteksi *pneumonia* dibandingkan dengan kondisi normal, angka *False Negatives* ini cukup tinggi, yang berarti ada risiko bahwa sejumlah pasien dengan *pneumonia* mungkin tidak terdeteksi dan dianggap sehat. Secara keseluruhan, model RNN menunjukkan kemampuan yang kuat dalam mendeteksi *pneumonia* dengan tingkat keberhasilan yang tinggi, namun kelemahan dalam hal mendeteksi kondisi normal dan kecenderungan untuk membuat kesalahan dalam mengidentifikasi kasus negatif palsu dan positif palsu menunjukkan perlunya perbaikan lebih lanjut. Setelah dilakukan analisis berdasarkan nilai *confusion matrix*, maka dapat dilakukan analisis lanjut dengan menggunakan nilai metrik pengujian berupa presisi, *recall* dan *f1-score* yang dihasilkan dari pengolahan nilai pada *confusion matriks*. Untuk hasil metrik presisi, *recall* dan *f1-score* yang didapatkan setelah melakukan pengujian pada model dalam masing masing kelas diberikan pada tabel 4.3.

Tabel 4. 3. Hasil Pengujian Model

Kelas	Precision	Recall	F1-Score
NORMAL	0.61	0.72	0.66
PNEUMONIA	0.81	0.72	0.76

Tabel 4.3 menunjukkan nilai presisi, recall, f1-score, dan support yang dihasilkan ketika melakukan proses pengujian menggunakan model *Recurrent Neural Network* (RNN) yang telah dilatih. Dapat dilihat pada Tabel 4.3, model menunjukkan variasi performa yang signifikan antara kedua kelas yang diuji, yaitu "Normal" dan "Pneumonia." Dapat dilihat pada tabel 4.3, Pada kelas "Normal," nilai presisi sebesar 0.61 menunjukkan bahwa dari semua prediksi yang menyatakan seorang pasien normal, hanya 61% yang benar-benar normal. Ini mengindikasikan bahwa model cenderung menghasilkan beberapa *False Positives* untuk kelas "Normal," di mana pasien yang sebenarnya menderita *pneumonia* justru terdeteksi sebagai normal. Hal ini bisa berkontribusi pada tingginya angka *False Negatives* pada kategori "Pneumonia." Sebaliknya, untuk kelas "Pneumonia," model menunjukkan presisi yang lebih tinggi, yakni 0.81. Ini berarti model lebih dapat diandalkan dalam mengidentifikasi pasien yang menderita *pneumonia* dengan sedikit kesalahan dalam mendeteksi pasien yang sehat sebagai sakit. Selanjutnya, dapat dilihat pada tabel 1, Nilai *recall* pada kedua kelas, baik "Normal" maupun "Pneumonia," adalah 0.72. Ini menunjukkan bahwa model memiliki tingkat kemampuan yang sama dalam mendeteksi kedua kelas secara benar. Meskipun demikian, nilai recall yang sama antara kedua kelas ini tidak menjamin keseimbangan keseluruhan dalam kinerja model, mengingat presisi yang berbeda di antara kedua kelas. Untuk kelas "Pneumonia," nilai *recall* ini menunjukkan bahwa model berhasil mendeteksi 72% dari seluruh kasus *pneumonia* yang ada, namun masih ada 28% kasus yang tidak terdeteksi, yang dapat menjadi perhatian serius dalam konteks medis.

Selanjutnya pada tabel 4.3, dapat dilihat bahwa Pada kelas "Normal," *F1-Score* adalah 0.66, yang mengindikasikan bahwa performa model dalam mendeteksi kelas ini masih cukup moderat, dan ada ruang untuk perbaikan lebih lanjut. Untuk kelas "*Pneumonia*," nilai *F1-Score* adalah 0.76, menunjukkan performa yang lebih baik dalam mendeteksi *pneumonia* dibandingkan kelas "Normal." Meskipun *F1-Score* yang lebih tinggi pada kelas "*Pneumonia*" menunjukkan bahwa model lebih akurat dalam mendeteksi pasien yang sakit, namun masih ada potensi perbaikan untuk meningkatkan keseimbangan antara presisi dan *recall*, khususnya untuk kelas "Normal." Secara keseluruhan, analisis dari Tabel 1 mengindikasikan bahwa model RNN memiliki kinerja yang cukup baik dalam mendeteksi *pneumonia*, dengan presisi dan *F1-Score* yang lebih tinggi dibandingkan dengan deteksi kondisi normal. Namun, kelemahan dalam mendeteksi kasus normal dan kesenjangan dalam presisi antara dua kelas menunjukkan bahwa ada ruang untuk perbaikan. Setelah dilakukan proses analisis dengan melihat nilai presisi, *recall* dan *f1-score* pada model RNN yang telah dilatih, maka untuk lebih dalam melihat performa model dalam melakukan proses klasifikasi, dapat dilihat pula kinerja umum model dalam melakukan proses klasifikasi dengan melihat nilai *macro avg*, *micro avg* dan akurasi model. Untuk hasil pengujian lanjutan diberikan pada tabel 4.4.

Tabel 4. 4. Hasil pengujian lanjutan

	Presisi	Recall	F1-Score	Accuracy
Macro Avg	0.71	0.72	0.71	72%
Micro Avg	0.73	0.72	0.72	

Tabel 4.4 menunjukkan nilai perhitungan general untuk mengukur kinerja model pada proses klasifikasi penyakit *pneumonia*. Dapat dilihat pada Tabel 4.4, metrik yang digunakan untuk mengevaluasi performa model mencakup *Macro Average*, *Micro Average*, serta Akurasi secara keseluruhan. *Macro Average* merupakan rata-rata dari nilai

presisi, *recall*, dan *F1-Score* yang dihitung tanpa mempertimbangkan jumlah sampel di setiap kelas. Dalam hal ini, nilai presisi, *recall*, dan *F1-Score* masing-masing adalah 0.71, 0.72, dan 0.71. *Macro Average* memberikan pandangan tentang performa model pada setiap kelas dengan bobot yang sama, tanpa memperhatikan apakah kelas tersebut memiliki jumlah sampel yang besar atau kecil. Nilai *Macro Average* ini menunjukkan bahwa secara umum, model memiliki performa yang cukup stabil antara kelas "Normal" dan "Pneumonia." Namun, nilai yang sedikit lebih rendah dari perfect score (1.0) menunjukkan adanya beberapa kesalahan dalam klasifikasi, baik dalam mendeteksi pasien yang sehat sebagai *pneumonia* maupun sebaliknya. Ini bisa menjadi indikator bahwa model masih perlu perbaikan, terutama dalam menangani ketidakseimbangan antara kedua kelas tersebut. *Micro Average* dihitung dengan menjumlahkan seluruh *true positives*, *false negatives*, dan *false positives*, lalu menggunakan nilai-nilai ini untuk menghitung presisi, *recall*, dan *F1-Score*. Nilai presisi, *recall*, dan *F1-Score* untuk *Micro Average* masing-masing adalah 0.73, 0.72, dan 0.72. *Micro Average* memberikan pandangan yang lebih akurat terhadap performa keseluruhan model dengan memperhitungkan kontribusi dari semua kelas sesuai dengan ukuran dataset masing-masing kelas. Dalam kasus ini, nilai *Micro Average* yang sedikit lebih tinggi dibandingkan *Macro Average* menunjukkan bahwa model mungkin memiliki kinerja yang lebih baik pada kelas yang lebih dominan, dalam hal ini "Pneumonia." Ini wajar, mengingat distribusi *dataset* yang tidak seimbang di mana kasus *pneumonia* lebih banyak dibandingkan dengan kasus normal. Namun, nilai ini juga menunjukkan bahwa ada beberapa *false negatives* yang dihasilkan, terutama pada kelas dengan jumlah sampel yang lebih sedikit.

Dapat dilihat pada tabel 4.4, nilai Akurasi pengujian model yaitu 72%, yang mengindikasikan bahwa model mampu membuat prediksi yang benar untuk 72% dari total sampel. Akurasi ini memberikan gambaran umum tentang seberapa sering model melakukan prediksi yang benar, tetapi tidak mempertimbangkan perbedaan dalam

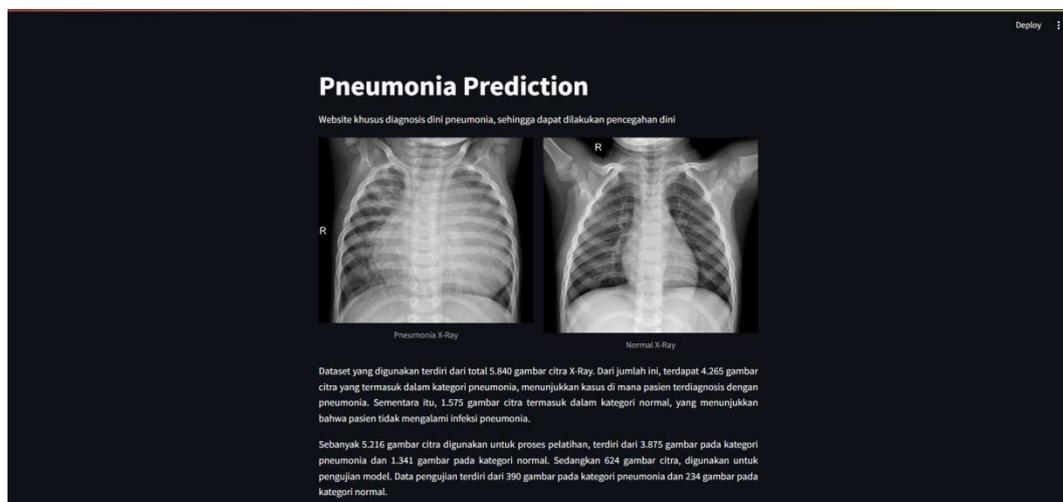
keseriusan kesalahan antara kelas yang berbeda. Dengan akurasi sebesar 72%, model dapat dikatakan cukup baik dalam mengklasifikasikan *pneumonia*, tetapi ada potensi kesalahan yang cukup signifikan, terutama dalam mengidentifikasi pasien yang sehat sebagai sakit atau sebaliknya. Akurasi ini perlu dilihat dalam konteks presisi dan *recall* dari masing-masing kelas, terutama dalam aplikasi medis di mana kesalahan kecil sekalipun bisa memiliki konsekuensi serius. Berdasarkan analisis dari Tabel 2, terlihat bahwa model *Recurrent Neural Network* (RNN) yang dibangun memiliki kinerja yang cukup memadai dalam mendeteksi *pneumonia*, namun masih ada ruang untuk peningkatan. Nilai *Macro* dan *Micro Average* yang mendekati satu sama lain mengindikasikan bahwa model memiliki konsistensi dalam performa prediksi *pneumonia*.

4.4 Implementasi Sistem

Setelah dilakukan proses pelatihan dan pengujian model, langkah berikutnya dalam penelitian ini adalah implementasi sistem yang bertujuan untuk mengkomersialkan model yang telah dibangun serta mempercepat proses diagnosis penyakit *pneumonia*. Dalam implementasi ini, model *Recurrent Neural Network* (RNN) yang telah dilatih sebelumnya akan digunakan untuk mengembangkan sebuah aplikasi berbasis *website* yang sederhana. Aplikasi ini memungkinkan pengguna untuk mengunggah citra *X-ray* ke dalam sistem, yang kemudian secara otomatis akan menjalankan proses klasifikasi untuk menentukan apakah gambar tersebut menunjukkan kondisi normal atau *pneumonia*.

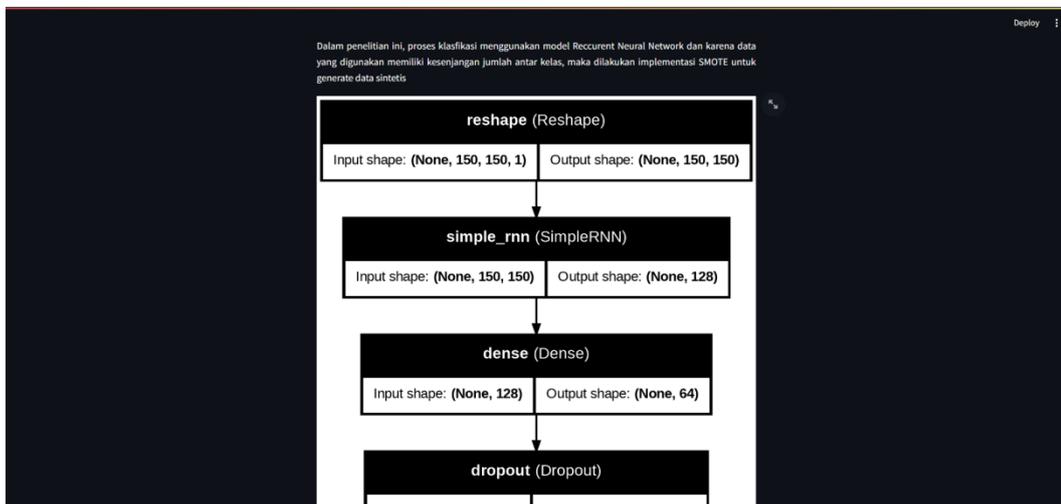
Pengembangan *website* ini dilakukan menggunakan *Streamlit*, sebuah *library Python* yang dirancang untuk mempermudah pembuatan antarmuka pengguna interaktif tanpa memerlukan keahlian mendalam dalam pengembangan *website*. Pemilihan *Streamlit* dalam penelitian ini didasari oleh kemampuannya untuk mengintegrasikan model *machine learning* yang telah dilatih ke dalam antarmuka pengguna yang ramah dan intuitif. Dengan *Streamlit*, pengguna akhir dapat dengan mudah berinteraksi dengan

model, mengunggah citra *X-ray*, dan langsung melihat hasil klasifikasi yang ditampilkan dengan visualisasi yang jelas dan mudah dipahami. Tidak hanya itu, *Streamlit* juga memungkinkan visualisasi hasil prediksi yang interaktif dan dinamis, sehingga meningkatkan pengalaman pengguna dalam proses identifikasi penyakit. Aplikasi ini tidak hanya dirancang untuk mencapai akurasi tinggi dalam klasifikasi, tetapi juga untuk memastikan bahwa pengguna, termasuk tenaga medis yang mungkin tidak memiliki latar belakang teknis, dapat menggunakan aplikasi ini dengan mudah dan efektif. Dengan demikian, aplikasi *website* yang dikembangkan dalam penelitian ini tidak hanya efektif dalam membantu proses diagnosis *pneumonia* dengan cepat dan akurat, tetapi juga dirancang dengan mempertimbangkan kemudahan penggunaan dan interaktivitas, sehingga dapat diadopsi dengan mudah oleh berbagai pengguna di lingkungan medis. Tampilan antarmuka yang sederhana dan *user-friendly* akan mempermudah implementasi di rumah sakit atau klinik, di mana hasil diagnosa yang cepat dan akurat sangat penting. Visualisasi tampilan halaman *website* sederhana yang dibangun diberikan pada Gambar 4.7.



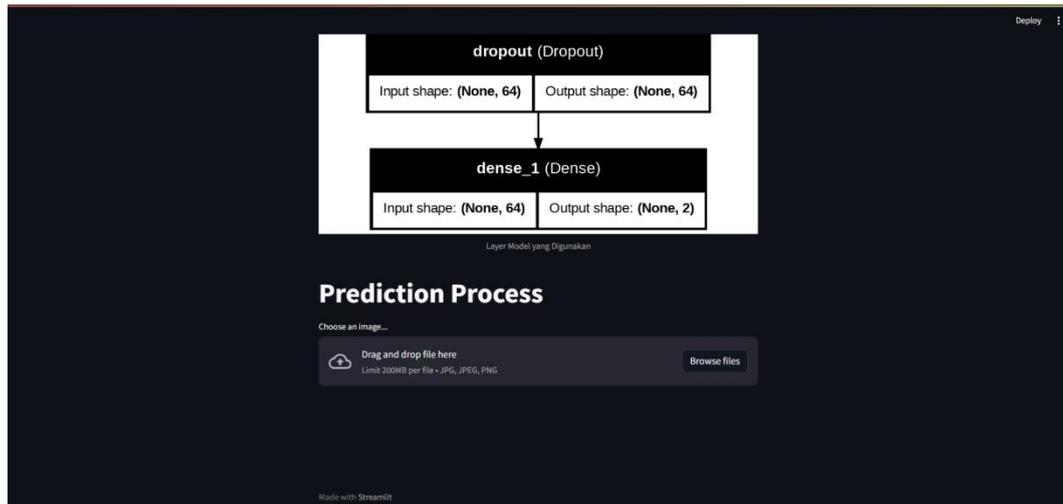
Gambar 4. 7. Tampilan wesbite 1

Gambar 4.7 menunjukkan tampilan sekilas dari *website* yang telah dibangun untuk aplikasi klasifikasi penyakit *pneumonia*. Pada tampilan utama *website*, terdapat penjelasan menyeluruh mengenai tujuan dari *website* ini, yaitu untuk melakukan prediksi penyakit *pneumonia* menggunakan model *deep learning*. Hal ini ditunjukkan dengan penjelasan yang jelas dan informatif tentang bagaimana *website* ini dapat membantu pengguna dalam mendiagnosis *pneumonia* secara otomatis. Selain itu, pada tampilan *website*, juga disediakan informasi mengenai dataset yang digunakan dalam pembangunan model. Informasi ini mencakup deskripsi rinci mengenai sumber data, format data, serta proses pembersihan dan pra-pemrosesan yang dilakukan pada *dataset*. Dengan adanya penjelasan ini, pengguna dapat memahami secara mendalam bagaimana dataset yang digunakan mempengaruhi akurasi dan efektivitas model. Bagian *website* ini dirancang untuk memberikan transparansi dan keterbukaan mengenai data yang digunakan dalam model, sehingga pengguna tidak hanya mendapatkan hasil prediksi tetapi juga memiliki wawasan tentang dasar ilmiah dan teknis di balik sistem. Ini bertujuan untuk meningkatkan kepercayaan pengguna terhadap sistem serta memberikan mereka informasi yang diperlukan untuk memahami proses yang terjadi di balik layar. Untuk tampilan *website* lebih lanjut diberikan pada gambar 4.8.



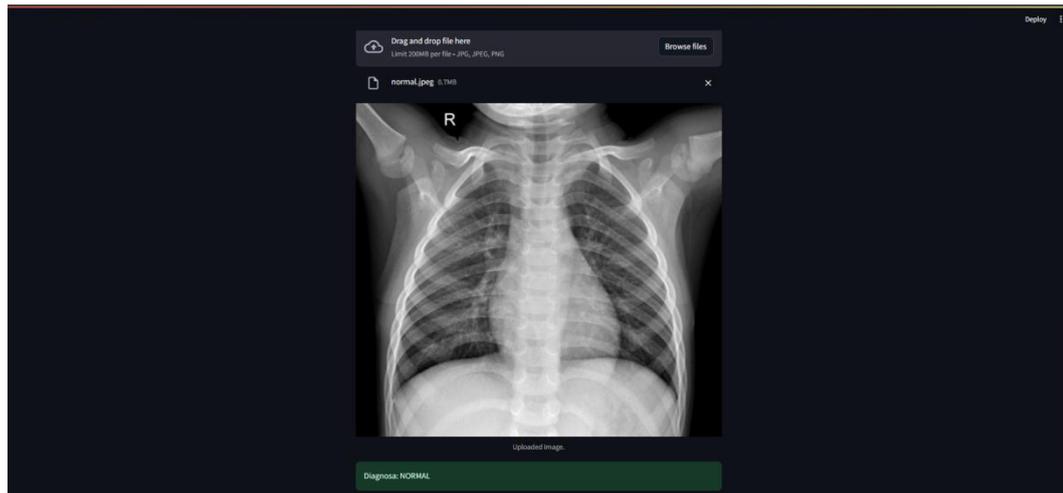
Gambar 4. 8. Tampilan wabsite 2

Gambar 4.8 menunjukkan tampilan lebih lanjut dari *website* yang dikembangkan dalam penelitian ini. Pada tampilan ini, pengguna dapat melihat representasi visual dari arsitektur model yang digunakan dalam sistem, khususnya *layer-layer* dari *Recurrent Neural Network* (RNN) yang dibangun untuk klasifikasi *pneumonia*. Di bagian ini, *website* menampilkan diagram atau grafik yang menjelaskan struktur RNN secara mendetail. Diagram tersebut mencakup berbagai *layer* yang membentuk model, termasuk *layer input*, *hidden layers*, dan *layer output*, beserta *parameter-parameter* kunci dari setiap *layer*. Penjelasan ini memberikan wawasan kepada pengguna mengenai bagaimana data diproses melalui model, serta bagaimana setiap *layer* berkontribusi pada proses klasifikasi. Selain itu, tampilan ini juga mencakup deskripsi fungsi dari setiap layer dalam konteks model RNN. Misalnya, pengguna dapat melihat informasi tentang jenis layer yang digunakan (seperti LSTM atau GRU), ukuran *hidden state*, dan mekanisme regularisasi yang diterapkan untuk menghindari *overfitting*. Dengan cara ini, pengguna tidak hanya melihat hasil akhir dari model, tetapi juga mendapatkan pemahaman yang lebih mendalam tentang bagaimana model tersebut dibangun dan berfungsi. Informasi ini dirancang untuk memberikan transparansi tentang struktur dan kompleksitas model, membantu pengguna untuk lebih memahami bagaimana model mencapai keputusan klasifikasi. Ini juga berfungsi untuk mendemonstrasikan pendekatan ilmiah dan teknis yang digunakan dalam penelitian, sehingga meningkatkan kepercayaan dan pemahaman pengguna terhadap sistem yang telah disediakan sebelumnya. Untuk tampilan lanjutan *website* diberikan pada gambar 4.9 berikut.



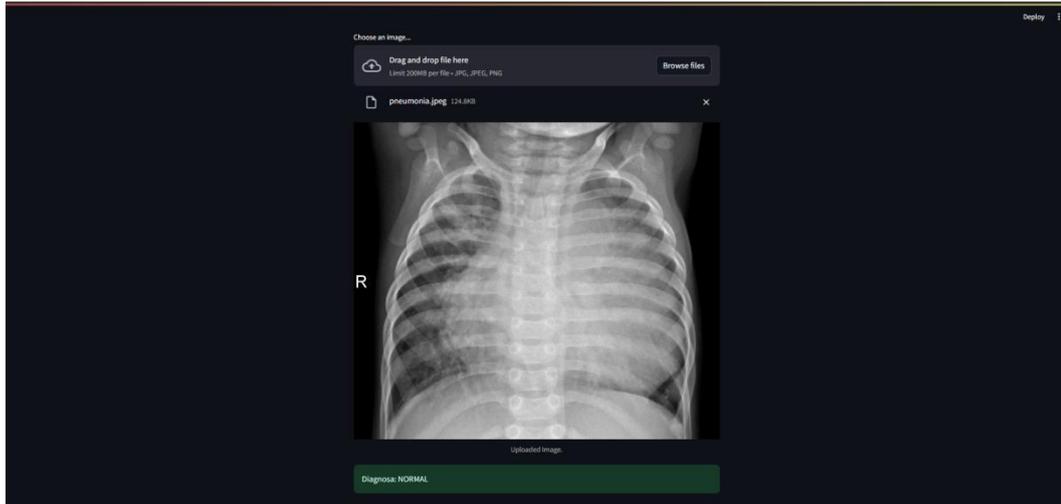
Gambar 4. 9. Tampilan website 3

Gambar 4.9 menunjukkan tampilan lanjutan dari *website* yang dikembangkan dalam penelitian ini. Pada tampilan ini, fitur utama yang ditampilkan adalah proses prediksi yang dilakukan oleh sistem. Pengguna dapat melihat area khusus di *website* yang dirancang untuk menerima input data dari citra *X-ray*. Pada lokasi yang telah disediakan, pengguna dapat mengunggah citra *X-ray* yang ingin dianalisis. Setelah citra diunggah, model yang diimplementasikan pada *website* akan segera memproses citra tersebut untuk melakukan prediksi. Tampilan ini menampilkan antarmuka yang memudahkan pengguna untuk mengupload citra *X-ray* dengan beberapa fitur interaktif, seperti tombol unggah (*upload button*) dan *preview* citra sebelum pengolahan. Setelah citra diunggah, sistem secara otomatis memulai proses prediksi menggunakan model yang telah dilatih. Hasil prediksi kemudian ditampilkan langsung pada *website*, memberikan informasi tentang kemungkinan adanya *pneumonia* dan tingkat kepercayaannya. Informasi ini disajikan dengan cara yang jelas dan mudah dipahami, termasuk label hasil prediksi. Untuk contoh Ketika dilakukan proses input pada *website* diberikan pada gambar 4.10.



Gambar 4. 10. Tampilan website 4

Gambar 4.10 menunjukkan hasil dari proses input yang telah dilakukan pada *website*. Dalam gambar ini, dapat dilihat bagaimana sistem memberikan diagnosis berdasarkan citra *X-ray* yang diinputkan oleh pengguna. Tampilan ini menunjukkan antarmuka di mana pengguna dapat mengunggah citra *X-ray* dan langsung menerima hasil diagnosis. Ketika citra *X-ray* yang normal diinputkan, model dengan jelas menunjukkan prediksi yang akurat sesuai dengan kondisi kesehatan yang terdeteksi dalam citra tersebut. Pada Gambar 14, hasil menunjukkan bahwa model berhasil mengidentifikasi citra *X-ray* normal dengan tepat, memberikan prediksi yang sesuai dan akurat. Informasi ini disertai dengan label hasil prediksi, sehingga pengguna dapat memahami hasil diagnosis yang diberikan. Selanjutnya, untuk membandingkan dan menunjukkan bagaimana model menangani kasus input yang salah atau citra yang tidak sesuai, referensi tampilan model untuk hasil prediksi yang salah dapat dilihat pada Gambar 4.11.



Gambar 4. 11. Tampilan website 5

Gambar 4.11 menunjukkan tampilan model saat melakukan prediksi pada *website*. Dalam gambar ini, dapat dilihat situasi di mana model menghasilkan hasil prediksi yang salah. Tampilan ini menunjukkan bagaimana model memberikan diagnosis ketika citra *X-ray* yang diinputkan menghasilkan hasil prediksi yang tidak akurat. Gambar 15 menyajikan contoh di mana diagnosis yang diberikan oleh model tidak sesuai dengan kondisi sebenarnya dari citra *X-ray* yang diunggah.

BAB V PENUTUP

5.1 Kesimpulan

Dalam penelitian ini, telah dilakukan proses pembangunan model *Recurrent Neural Network* (RNN) untuk menganalisis dataset yang telah diproses menggunakan metode *Synthetic Minority Over-Sampling Technique* (SMOTE). Hal ini dilakukan karena dataset yang digunakan dalam penelitian ini memiliki distribusi data yang tidak merata, terutama dalam konteks prediksi penyakit *pneumonia*. SMOTE diterapkan untuk mengatasi ketidakseimbangan kelas yang ada, dengan cara menambahkan sampel sintetis untuk kelas minoritas agar distribusi data menjadi lebih seimbang. Kesimpulan yang didapatkan dari penelitian ini dijabarkan sebagai berikut:

1. Penggunaan SMOTE terbukti efektif dalam memperbaiki ketidakseimbangan kelas dalam *dataset*, terbukti sebelum menggunakan SMOTE, data yang awalnya terdiri dari 4.265 citra kategori *pneumonia* dan 1.575 citra kategori normal, menjadi sebanyak 4.265 data dalam kategori *pneumonia* dan 4.265 data dalam kategori normal. Dengan menambah jumlah sampel untuk kelas minoritas, model RNN dapat dilatih dengan data yang lebih seimbang, sehingga meningkatkan kemampuan model dalam mengidentifikasi kasus penyakit *pneumonia* dengan lebih akurat.
2. Model RNN yang dibangun menunjukkan kemampuan yang baik dalam memproses data citra *X-ray* dan memberikan prediksi yang sesuai, yang Dimana hal tersebut dapat dilihat setelah proses pengujian model mendapatkan akurasi sebesar 72%. Akan tetapi, meskipun akurasi yang dihasilkan optimal, algoritma RNN masih kemungkinan terjadinya kesalahan dalam beberapa prediksi, penggunaan RNN memungkinkan deteksi yang lebih baik terhadap pola temporal dan konteks dalam data citra yang dianalisis.

3. Implementasi *website* menggunakan metode *streamlit* dapat bekerja dengan baik dan optimal dalam menyediakan tampilan serta kemudahan penggunaan kepada pengguna dalam melakukan proses diagnosis penyakit *pneumonia*, sehingga memungkinkan pengguna dapat melakukan diagnosis dengan cepat dan bisa memberikan rekomendasi sesuai citra *X-Ray* yang di inputkan.

5.2 Saran

Berdasarkan hasil dan kesimpulan yang telah diberikan, terdapat beberapa area pengembangan yang dapat ditingkatkan untuk penelitian selanjutnya dengan tujuan meningkatkan akurasi pengujian. Berikut adalah saran penelitian yang dapat dipertimbangkan:

1. Menguji dan membandingkan model deep learning lainnya, seperti *Convolutional Neural Networks* (CNN) atau kombinasi CNN dengan RNN, untuk melihat apakah mereka dapat memberikan hasil yang lebih baik dalam prediksi penyakit *pneumonia*. Model-model ini dapat menangkap fitur visual dari citra *X-ray* secara lebih mendalam.
2. Menerapkan teknik data *augmentation* untuk meningkatkan variasi dalam *dataset* yang ada. Teknik ini dapat meliputi rotasi, pemotongan, dan perubahan kontras citra *X-ray*, yang dapat membantu model dalam menghadapi berbagai kondisi citra dan meningkatkan generalisasi.
3. Melakukan *fine-tuning* pada model RNN dengan eksperimen yang lebih mendalam pada *hyperparameter*, seperti jumlah *layer*, ukuran *hidden state*, dan *learning rate*, untuk menemukan konfigurasi yang optimal.

DAFTAR PUSTAKA

- Huang L, Zhang X, Pang L, et al. Viral reactivation in the lungs of patients with severe pneumonia is associated with increased mortality, a multicenter, retrospective study. *J Med Virol*. 2022; 95:e28337. [doi:10.1002/jmv.28337](https://doi.org/10.1002/jmv.28337)
- Murphy, C. N., Fowler, R., Balada-Llasat, J. M., Carroll, A., Stone, H., Akerele, O., Buchan, B., Windham, S., Hopp, A., Ronen, S., Relich, R. F., Buckner, R., Warren, D. A., Humphries, R., Campeau, S., Huse, H., Chandrasekaran, S., Leber, A., Everhart, K., ... Bourzac, K. M. (2020). Multicenter evaluation of the BioFire FilmArray Pneumonia/ Pneumonia plus panel for detection and quantification of agents of lower respiratory tract infection. *Journal of Clinical Microbiology*, 58(7). <https://doi.org/10.1128/JCM.00128-20>
- Çınar, A., Yıldırım, M., & Eroğlu, Y. (2021). Classification of pneumonia cell images using improved ResNet50 model. *Traitement Du Signal*, 38(1), 165–173. <https://doi.org/10.18280/TS.380117>
- Alsharif, R., Al-Issa, Y., Alqudah, A. M., Qasmieh, I. A., Mustafa, W. A., & Alquran, H. (2021). Pneumoninet: Automated detection and classification of pediatric pneumonia using chest x-ray images and cnn approach. *Electronics (Switzerland)*, 10(23). <https://doi.org/10.3390/electronics10232949>
- Shah, S., Mehta, H., & Sonawane, P. (2020). Pneumonia detection using convolutional neural networks. *Proceedings of the 3rd International Conference on Smart Systems and Inventive Technology, ICSSIT 2020*, 933–939. <https://doi.org/10.1109/ICSSIT48917.2020.9214289>
- Chouhan, V., Singh, S. K., Khamparia, A., Gupta, D., Tiwari, P., Moreira, C., Damaševičius, R., & de Albuquerque, V. H. C. (2020). A novel transfer learning based approach for pneumonia detection in chest X-ray images. *Applied Sciences (Switzerland)*, 10(2). <https://doi.org/10.3390/app10020559>
- Jain, R., Nagrath, P., Kataria, G., Sirish Kaushik, V., & Jude Hemanth, D. (2020). Pneumonia detection in chest X-ray images using convolutional neural networks and transfer learning. *Measurement: Journal of the International Measurement Confederation*, 165. <https://doi.org/10.1016/j.measurement.2020.108046>

- E. Ayan and H. M. Ünver, "Diagnosis of Pneumonia from Chest X-Ray Images Using Deep Learning," 2019 Scientific Meeting on Electrical-Electronics & Biomedical Engineering and Computer Science (EBBT), Istanbul, Turkey, 2019, pp. 1-5, doi: 10.1109/EBBT.2019.8741582.
- Rahman, T., Chowdhury, M. E. H., Khandakar, A., Islam, K. R., Islam, K. F., Mahbub, Z. B., Kadir, M. A., & Kashem, S. (2020). Transfer learning with deep Convolutional Neural Network (CNN) for pneumonia detection using chest X-ray. *Applied Sciences (Switzerland)*, 10(9). <https://doi.org/10.3390/app10093233>
- Moen, E., Bannon, D., Kudo, T., Graf, W., Covert, M., & van Valen, D. (2019). Deep learning for cellular image analysis. In *Nature Methods* (Vol. 16, Issue 12, pp. 1233–1246). Nature Research. <https://doi.org/10.1038/s41592-019-0403-1>
- Bolón-Canedo, V., & Remeseiro, B. (2020). Feature selection in image analysis: a survey. *Artificial Intelligence Review*, 53(4), 2905–2931. <https://doi.org/10.1007/s10462-019-09750-3>
- J., Jumadi, J., & Sartika, D. (2021). *PENGOLAHAN CITRA DIGITAL UNTUK IDENTIFIKASI OBJEK MENGGUNAKAN METODE HIERARCHICAL AGGLOMERATIVE CLUSTERING*. <https://doi.org/10.23887/jstundiksha.v10i2.33636>
- Kufel, J.; Bargieł-Lączek, K.; Kocot, S.; Koźlik, M.; Bartnikowska, W.; Janik, M.; Czogalik, Ł.; Dudek, P.; Magiera, M.; Lis, A.; et al. What Is Machine Learning, Artificial Neural Networks and Deep Learning? — Examples of Practical Applications in Medicine. *Diagnostics* 2023, 13, 2582. <https://doi.org/10.3390/diagnostics13152582>
- Dong, S., Wang, P., & Abbas, K. (2021). A survey on deep learning and its applications. *Computer Science Review*, 40, 100379. <https://doi.org/10.1016/j.cosrev.2021.100379>
- Sharma, N., Sharma, R., & Jindal, N. (2021). Machine Learning and Deep Learning Applications—A Vision. *Global Transitions Proceedings*, 2(1), 24-28. <https://doi.org/10.1016/j.gltip.2021.01.004>
- Sherstinsky, A. (2020). Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) network. *Physica D: Nonlinear Phenomena*, 404, 132306. <https://doi.org/10.1016/j.physd.2019.132306>

- Yadav, S.P., Zaidi, S., Mishra, A. *et al.* Survey on Machine Learning in Speech Emotion Recognition and Vision Systems Using a Recurrent Neural Network (RNN). *Arch Computat Methods Eng* **29**, 1753–1770 (2022). <https://doi.org/10.1007/s11831-021-09647-x>
- Wang, S., Dai, Y., Shen, J. *et al.* Research on expansion and classification of imbalanced data based on SMOTE algorithm. *Sci Rep* **11**, 24039 (2021). <https://doi.org/10.1038/s41598-021-03430-5>
- D. Dablain, B. Krawczyk and N. V. Chawla, "DeepSMOTE: Fusing Deep Learning and SMOTE for Imbalanced Data," in *IEEE Transactions on Neural Networks and Learning Systems*, vol. 34, no. 9, pp. 6390-6404, Sept. 2023, doi: 10.1109/TNNLS.2021.3136503.
- Rifky, S. (2024). Dampak Penggunaan Artificial Intelligence Bagi Pendidikan Tinggi. *Indonesian Journal of Multidisciplinary on Social and Technology*, 2(1), 37–42. <https://doi.org/10.31004/ijmst.v2i1.287>
- Zebua, E. T. P., & Rosyani, P. (2024). Perancangan deteksi objek kendaraan bermotor berbasis OpenCV Python menggunakan metode HOG-SVM untuk analisis lalu lintas cerdas. *AI dan SPK: Jurnal Artificial Intelligent dan Sistem Penunjang Keputusan*, 2(1), 16–26. Retrieved from <http://jurnalmahasiswa.com/index.php/aidanspk/article/view/1488>
- Ngugi, L. C., Abelwahab, M., & Abo-Zahhad, M. (2021). Recent advances in image processing techniques for automated leaf pest and disease recognition – A review. *Information Processing in Agriculture*, 8(1), 27-51. <https://doi.org/10.1016/j.inpa.2020.04.004>
- M. A. Jasim and J. M. AL-Tuwaijari, "Plant Leaf Diseases Detection and Classification Using Image Processing and Deep Learning Techniques," *2020 International Conference on Computer Science and Software Engineering (CSASE)*, Duhok, Iraq, 2020, pp. 259-265, doi: 10.1109/CSASE48920.2020.9142097.
- Roberts, D. A., Yaida, S., & Hanin, B. (2022). Frontmatter. In *The Principles of Deep Learning Theory: An Effective Theory Approach to Understanding Neural Networks* (pp. i–iv). frontmatter, Cambridge: Cambridge University Press.
- Janiesch, C., Zschech, P. & Heinrich, K. Machine learning and deep learning. *Electron Markets* **31**, 685–695 (2021). <https://doi.org/10.1007/s12525-021-00475-2>

- Wang, P., Fan, E., & Wang, P. (2021). Comparative analysis of image classification algorithms based on traditional machine learning and deep learning. *Pattern Recognition Letters*, *141*, 61-67. <https://doi.org/10.1016/j.patrec.2020.07.042>
- Ullah and Q. H. Mahmoud, "Design and Development of RNN Anomaly Detection Model for IoT Networks," in *IEEE Access*, vol. 10, pp. 62722-62750, 2022, doi: 10.1109/ACCESS.2022.3176317.
- Kanakala, R. V., Mohan, J. K., & Reddy, K. V. (2023). Modelling a deep network using CNN and RNN for accident classification. *Measurement: Sensors*, *27*, 100794. <https://doi.org/10.1016/j.measen.2023.100794>
- Ishaq *et al.*, "Improving the Prediction of Heart Failure Patients' Survival Using SMOTE and Effective Data Mining Techniques," in *IEEE Access*, vol. 9, pp. 39707-39716, 2021, doi: 10.1109/ACCESS.2021.3064084.
- Li, J., Zhu, Q., Wu, Q., & Fan, Z. (2021). A novel oversampling technique for class-imbalanced learning based on SMOTE and natural neighbors. *Information Sciences*, *565*, 438-455. <https://doi.org/10.1016/j.ins.2021.03.041>
- Xu, J., Zhang, Y., & Miao, D. (2020). Three-way confusion matrix for classification: A measure driven view. *Information Sciences*, *507*, 772-794. <https://doi.org/10.1016/j.ins.2019.06.064>
- M. Hasnain, M. F. Pasha, I. Ghani, M. Imran, M. Y. Alzahrani and R. Budiarto, "Evaluating Trust Prediction and Confusion Matrix Measures for Web Services Ranking," in *IEEE Access*, vol. 8, pp. 90847-90861, 2020, doi: 10.1109/ACCESS.2020.2994222.
- Ramli, N. E., Yahya, Z. R., & Said, N. A. (2023). Confusion matrix as performance measure for corner detectors. *Journal of Advanced Research in Applied Sciences and Engineering Technology*, *29*(1), 256–265. <https://doi.org/10.37934/araset.29.1.256265>
- Riehl, K., Neunteufel, M., & Hemberg, M. (2023). Hierarchical confusion matrix for classification performance evaluation. *Journal of the Royal Statistical Society: Series C (Applied Statistics)*, *72*(5), 1394–1412. <https://doi.org/10.1093/jrssc/qlad057>
- Chicco, D., Jurman, G. The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. *BMC Genomics* **21**, 6 (2020). <https://doi.org/10.1186/s12864-019-6413-7>

- Ritonga, A., & Yahfizham, Y. (2023). Studi literatur perbandingan bahasa pemrograman C++ dan bahasa pemrograman Python pada algoritma pemrograman. *Jurnal Teknik Informatika dan Teknologi Informasi*, 3(3), 56–63. <https://doi.org/10.55606/jutiti.v3i3.2863>
- E. Kauhanen, J. K. Nurminen, T. Mikkonen and M. Pashkovskiy, "Regression Test Selection Tool for Python in Continuous Integration Process," *2021 IEEE International Conference on Software Analysis, Evolution and Reengineering (SANER)*, Honolulu, HI, USA, 2021, pp. 618-621, doi: 10.1109/SANER50967.2021.00077.
- Manimurugan, S. Retraction Note: Hybrid high performance intelligent computing approach of CACNN and RNN for skin cancer image grading. *Soft Comput* (2024). <https://doi.org/10.1007/s00500-024-09966-8>
- Imran, A., Li, J., Pei, Y. *et al.* Fundus image-based cataract classification using a hybrid convolutional and recurrent neural network. *Vis Comput* **37**, 2407–2417 (2021). <https://doi.org/10.1007/s00371-020-01994-3>
- Yan, R., Ren, F., Wang, Z., Wang, L., Zhang, T., Liu, Y., Rao, X., Zheng, C., & Zhang, F. (2020). Breast cancer histopathological image classification using a hybrid deep neural network. *Methods (San Diego, Calif.)*, 173, 52–60. <https://doi.org/10.1016/j.ymeth.2019.06.014>
- Veena, H.N., Patil, K.K., Vanajakshi, P. *et al.* An Enhanced RNN-LSTM Model for Fundus Image Classification to Diagnose Glaucoma. *SN COMPUT. SCI.* **5**, 514 (2024). <https://doi.org/10.1007/s42979-024-02867-5>
- Zamani, F., & Wulansari, R. (2021). Emotion classification using 1D-CNN and RNN based on deap dataset. *Nat. Lang. Process*, 363-378.

