

TESIS

**SEGMENTASI PARU-PARU PADA CITRA X-RAY DADA
MENGUNAKAN DEEP CONVOLUTIONAL NEURAL NETWORK
DENGAN ARSITEKTUR U-NET**



Disusun oleh:

Nama : Dinar Wakhid Putranto
NIM : 20.51.1359
Konsentrasi : Business Intelligence

**PROGRAM STUDI S2 TEKNIK INFORMATIKA
PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA**

2023

TESIS

**SEGMENTASI PARU-PARU PADA CITRA X-RAY DADA
MENGUNAKAN DEEP CONVOLUTIONAL NEURAL NETWORK
DENGAN ARSITEKTUR U-NET**

**LUNG SEGMENTATION IN CHEST X-RAY IMAGE USING DEEP
CONVOLUTIONAL NEURAL NETWORK WITH U-NET
ARCHITECTURE**

Diajukan untuk memenuhi salah satu syarat memperoleh derajat Magister



Disusun oleh:

Nama : Dinar Wakhid Putranto
NIM : 20.51.1359
Konsentrasi : Business Intelligence

**PROGRAM STUDI S2 TEKNIK INFORMATIKA
PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA**

2023

HALAMAN PENGESAHAN

SEGMENTASI PARU-PARU PADA CITRA X-RAY DADA
MENGUNAKAN DEEP CONVOLUTIONAL NEURAL NETWORK DENGAN
ARSITEKTUR U-NET

LUNG SEGMENTATION IN CHEST X-RAY IMAGE USING DEEP
CONVOLUTIONAL NEURAL NETWORK WITH U-NET ARCHITECTURE

Dipersiapkan dan Disusun oleh

Dinar Wakhid Putranto

20.51.1359

Telah Diujikan dan Dipertahankan dalam Sidang Ujian Tesis
Program Studi S2 Teknik Informatika
Program Pascasarjana Universitas AMIKOM Yogyakarta
pada hari Senin, 02 Oktober 2023

Tesis ini telah diterima sebagai salah satu persyaratan
untuk memperoleh gelar Magister Komputer

Yogyakarta, 02 Oktober 2023

Rektor

Prof. Dr. M. Suyanto, M.M.

NIK. 190302001

HALAMAN PERSETUJUAN

SEGMENTASI PARU-PARU PADA CITRA X-RAY DADA MENGUNAKAN DEEP CONVOLUTIONAL NEURAL NETWORK DENGAN ARSITEKTUR U-NET

LUNG SEGMENTATION IN CHEST X-RAY IMAGE USING DEEP CONVOLUTIONAL NEURAL NETWORK WITH U-NET ARCHITECTURE

Dipersiapkan dan Disusun oleh

Dinar Wakhid Putranto

20.51.1359

Telah Diujikan dan Dipertahankan dalam Sidang Ujian Tesis
Program Studi S2 Teknik Informatika
Program Pascasarjana Universitas AMIKOM Yogyakarta
pada hari Senin, 02 Oktober 2023

Pembimbing Utama

Dr. Andi Sunyoto, M.Kom.
NIK. 190302052

Anggota Tim Penguji

Prof. Dr. Ema Utami, S.Si., M.Kom.
NIK. 190302037

Pembimbing Pendamping

Drs. Asro Nasiri, M.Kom.
NIK. 190302152

Alva Hendi Muhammad, S.T., M.Eng., Ph.D.
NIK. 190302493

Dr. Andi Sunyoto, M.Kom.
NIK. 190302052

Tesis ini telah diterima sebagai salah satu persyaratan
untuk memperoleh gelar Magister Komputer

Yogyakarta, 02 Oktober 2023
Direktur Program Pascasarjana

Prof. Dr. Kusriani, M.Kom.
NIK. 190302106

HALAMAN PERNYATAAN KEASLIAN TESIS

Yang bertandatangan di bawah ini,

Nama mahasiswa : Dinar Wakhid Putranto

NIM : 20.51.1359

Konsentrasi : Business Intelligence

Menyatakan bahwa Tesis dengan judul berikut:

Segmentasi Paru-Paru pada Citra X-Ray Dada Menggunakan Deep Convolutional Neural Network dengan Arsitektur U-Net

Dosen Pembimbing Utama : Dr. Andi Sunyoto, M.Kom

Dosen Pembimbing Pendamping : Drs. Asro Nasiri, M.Kom.

1. Karya tulis ini adalah benar-benar ASLI dan BELUM PERNAH diajukan untuk mendapatkan gelar akademik, baik di Universitas AMIKOM Yogyakarta maupun di Perguruan Tinggi lainnya
2. Karya tulis ini merupakan gagasan, rumusan dan penelitian SAYA sendiri, tanpa bantuan pihak lain kecuali arahan dari Tim Dosen Pembimbing
3. Dalam karya tulis ini tidak terdapat karya atau pendapat orang lain, kecuali secara tertulis dengan jelas dicantumkan sebagai acuan dalam naskah dengan disebutkan nama pengarang dan disebutkan dalam Daftar Pustaka pada karya tulis ini
4. Perangkat lunak yang digunakan dalam penelitian ini sepenuhnya menjadi tanggung jawab SAYA, bukan tanggung jawab Universitas AMIKOM Yogyakarta
5. Pernyataan ini SAYA buat dengan sesungguhnya, apabila di kemudian hari terdapat penyimpangan dan ketidakbenaran dalam pernyataan ini, maka SAYA bersedia menerima SANKSI AKADEMIK dengan pencabutan gelar yang sudah diperoleh, serta sanksi lainnya sesuai dengan norma yang berlaku di Perguruan Tinggi

Yogyakarta, 02 Oktober 2023

Yang Menyatakan,

Dinar Wakhid Putranto

KATA PENGANTAR

Segala puji hanya bagi Allah Tuhan seluruh alam yang atas berkat dan rahmat-Nya penelitian ini dapat terlaksana. Penelitian yang berjudul “Segmentasi Paru-Paru pada Citra X-Ray Dada menggunakan Deep Convolutional Neural Network dengan Arsitektur U-Net” disusun sebagai salah satu syarat guna memperoleh gelar Magister pada Program Studi Magister Teknik Informatika Universitas Amikom Yogyakarta.

Penulis menyadari bahwa telah banyak penelitian mengenai segmentasi citra. Selain itu telah banyak penelitian mengenai pengolahan citra di bidang kesehatan. Dengan harapan dapat berkontribusi lebih pada bidang kesehatan dengan memanfaatkan teknologi informasi maka penelitian ini dilakukan untuk mendalami segmentasi citra biomedis khususnya citra *X-Ray* dada dengan memanfaatkan teknologi terkini.

Tidak lupa terima kasih saya ucapkan kepada Tim Dosen Pembimbing, Tim Dosen Penguji, dan semua pihak yang terkait dalam penyelesaian Tesis ini. Terimakasih saya ucapkan kepada:

- Kedua orang tua saya Budi Asnawi, M.Pd, M.Acc (Ayah) dan Sri Narti, M.Pd (Ibu) yang terus menerus tanpa lelah memberikan dukungan penuh baik secara moril maupun materiil;
- Dr. Andi Sunyoto, M.Kom selaku pembimbing utama yang telah memberikan arahan sejak awal hingga terselesaikannya tesis ini dan juga Drs. Asro Nasiri, M.Kom. selaku pembimbing pendamping;

- Untuk istri dan anak-anak yang menjadi motivasi, semangat dan harapan;
- Pihak manajemen RS Paru Respira dan rekan kerja tim yang telah memberikan kesempatan dan izin.

Penulis menyadari laporan ini masih jauh dari sempurna. Sehingga segala bentuk kritik dan saran yang membangun sangat Penulis harapkan. Akhir kata semoga laporan Tesis ini dapat memberikan manfaat untuk RS Paru Respira, untuk masyarakat dan untuk ilmu pengetahuan.

Yogyakarta, 02 Oktober 2023

Penulis



DAFTAR ISI

HALAMAN JUDUL.....	ii
HALAMAN PENGESAHAN.....	iii
HALAMAN PERSETUJUAN.....	iv
HALAMAN PERNYATAAN KEASLIAN TESIS.....	v
KATA PENGANTAR.....	vi
DAFTAR ISI.....	viii
DAFTAR TABEL.....	xii
DAFTAR GAMBAR.....	xiii
INTISARI.....	xv
<i>ABSTRACT</i>	xvi
BAB I PENDAHULUAN.....	1
1.1. Latar Belakang Masalah.....	1
1.2. Rumusan Masalah.....	6
1.3. Batasan Masalah.....	6
1.4. Tujuan Penelitian.....	7
1.5. Manfaat Penelitian.....	7
1.6. Hipotesis.....	7
BAB II TINJAUAN PUSTAKA.....	8
2.1. Tinjauan Pustaka.....	8
2.2. Keaslian Penelitian.....	13
2.3. Landasan Teori.....	21

2.3.1.	Dataset.....	21
2.3.2.	<i>Deep Learning</i>	23
2.3.3.	CNN.....	24
2.3.3.1.	Convolution Layer.....	25
2.3.3.2.	Pooling Layer.....	25
2.3.3.3.	<i>Normalization Layer</i>	26
2.3.3.4.	<i>Activation Layer</i>	26
2.3.3.5.	<i>Fully Connected Layer</i>	26
2.3.3.6.	Loss Layer.....	27
2.3.4.	U-Net.....	27
2.3.4.1.	Encoder.....	29
2.3.4.2.	Decoder.....	29
2.3.5.	Segmentasi.....	29
BAB III METODE PENELITIAN.....		32
3.1.	Jenis, Sifat, dan Pendekatan Penelitian.....	32
3.2.	Metode Pengumpulan Data.....	34
3.3.	Metode Analisis Data.....	35
3.4.	Alur Penelitian.....	35
3.4.1.	Dataset.....	36
3.4.1.1.	Analisa Dasar Dataset.....	37
3.4.1.2.	Struktur Dataset.....	39
3.4.1.3.	Tampilan Dataset.....	40
3.4.2.	Pra pemrosesan (pre processing).....	42

3.4.3.	Pembagian Dataset (Splitting).....	42
3.4.4.	Augmentasi.....	43
3.4.5.	Optimasi Learning-rate.....	43
3.4.6.	Pelatihan (Training) Model Segmentasi U-Net.....	44
3.4.6.1.	Input.....	44
3.4.6.2.	Konvolusi 3x3.....	45
3.4.6.3.	Max-Pooling.....	46
3.4.6.4.	Dekonvolusi atau Upsampling.....	47
3.4.6.5.	Dropout Layer.....	47
3.4.6.6.	Pengujian dan Evaluasi.....	48
BAB IV HASIL PENELITIAN DAN PEMBAHASAN.....		50
4.1.	Pengunduhan Dataset.....	50
4.2.	Analisa Dataset.....	51
4.3.	Pra Pemrosesan Dataset.....	53
4.3.1.	Penggabungan Anotasi Masking.....	53
4.3.2.	Resize.....	54
4.3.3.	Padding.....	56
4.3.4.	Augmentasi.....	57
4.4.	Melakukan Training Model Segmentasi U-Net.....	61
4.4.1.	Setup perangkat keras.....	61
4.4.2.	Setup perangkat lunak.....	62
4.4.3.	Menyusun Kode Program.....	63
4.5.	Hasil Training dan Validasi Model Segmentasi U-Net.....	66

4.5.1. Percobaan I	66
4.5.2. Percobaan II.....	70
4.5.3. Percobaan III	72
4.5.4. Percobaan IV	74
4.6. Hasil Pengujian dan Perbandingan	78
4.6.1. Hasil Pengujian.....	78
4.6.2. Performa Model.....	79
4.6.3. Perbandingan dengan Penelitian Sebelumnya.....	80
4.7. Output Segmentasi	84
BAB V PENUTUP.....	87
5.1. Kesimpulan	87
5.1.1. Menentukan set hyperparameter yang optimal untuk melatih model segmentasi paru-paru pada citra <i>X-Ray</i> dada menggunakan Deep CNN arsitektur U-Net	87
5.1.2. Modifikasi Deep CNN arsitektur U-Net untuk meningkatkan performa segmentasi paru-paru pada citra <i>X-Ray</i> dada	89
5.1.3. Nilai akurasi piksel dan nilai irisan segmentasi paru-paru pada citra <i>X-Ray</i> dada menggunakan Deep CNN arsitektur U-Net..	90
5.2. Saran	90
DAFTAR PUSTAKA	92

DAFTAR TABEL

Tabel 2. 1. Matriks literatur review dan posisi penelitian Segmentasi Paru-Paru dari Citra <i>X-Ray</i> Dada Menggunakan CNN dengan Arsitektur U-Net	13
Tabel 3. 1. Tampilan Dataset.....	40
Tabel 4. 1. Tabel Rincian Dataset.....	51
Tabel 4. 2 Hasil dari data augmentasi.....	57
Tabel 4. 3. Summary Model U-Net	63
Tabel 4. 4. Perbandingan Nilai akhir antara metode dekonvolusi <i>Simple Upsampling</i> dan <i>Transposed Convolution</i>	69
Tabel 4. 5. Tabel perbandingan nilai akhir untuk BN dan tanpa BN.....	71
Tabel 4. 6. Tabel Perbandingan <i>Batch Normalization</i> dan <i>Dropout</i>	73
Tabel 4. 7. Tabel Nilai Performa rentang dropout 10% hingga 90%	74
Tabel 4. 8. Perbandingan performa model.....	83
Tabel 4. 9. Visualisasi Output Segmentasi	84

DAFTAR GAMBAR

Gambar 2. 1. Hasil segmentasi dari metode konvensional (Yang et al. 2018)	9
Gambar 2. 2. Tampilan dari Sebagian dataset citra X-Ray dada.....	23
Gambar 2. 3. Diagram Arsitektur U-Net dimulai dari kiri sebagai input dan ke kanan sebagai output.....	28
Gambar 3. 1. Alur tahapan penelitian.....	36
Gambar 3. 2. Struktur Dataset	39
Gambar 3. 3. Contoh gambar X-Ray dada dan anotasi paru-parunya (Ground Truth) dengan proporsi resolusi asli.....	42
Gambar 3. 4. Gambar yang digunakan sebagai Input.....	45
Gambar 3. 5. Ilustrasi Konvolusi menghasilkan Lapisan Peta Fitur.....	46
Gambar 3. 6. Max-pooling menghasilkan ukuran $\frac{1}{2}$ dari sebelumnya	46
Gambar 3. 7. Ilustrasi Dropout pada Jaringan Syaraf	48
Gambar 3. 8. Ilustrasi Perhitungan Nilai Tumpang Tindih (IoU).....	49
Gambar 4. 1. Penggabungan Citra Masking	54
Gambar 4. 2 Resize terhadap citra X-Ray	55
Gambar 4. 3 Penambahan Padding	56
Gambar 4. 4. Diagram Model U-Net	65
Gambar 4. 5. Grafik perubahan tingkat akurasi metode <i>Simple Upsampling</i>	66
Gambar 4. 6 Grafik perubahan nilai loss metode <i>Simple Upsampling</i>	67
Gambar 4. 7 Grafik perubahan nilai IoU pada metode <i>Simple Upsampling</i>	67

Gambar 4. 8. Grafik tingkat akurasi pelatihan dengan metode dekonvolusi <i>Transposed Convolution</i>	68
Gambar 4. 9. Grafik nilai loss pada pelatihan metode dekonvolusi <i>Transposed Convolution</i>	68
Gambar 4. 10. Grafik perubahan nilai IoU pada pelatihan metode dekonvolusi <i>Transposed Convolution</i>	69
Gambar 4. 11. Posisi BN pada bagan model.....	70
Gambar 4. 12. Grafik percobaan <i>training</i> dengan <i>Batch Normalization</i>	71
Gambar 4. 13. Bagan penambahan fungsi DO.....	72
Gambar 4. 14. Gambar grafik perkembangan nilai pelatihan dan validasi dengan DO10%.....	73
Gambar 4. 15. Grafik perkembangan nilai akurasi penambahan DO	75

INTISARI

Pemeriksaan rontgen dada atau thoraks merupakan pemeriksaan penunjang yang paling umum digunakan dalam pendiagnosaan penyakit paru-paru. Selain karena dapat dilakukan dengan cepat dan praktis pemeriksaan rontgen lebih hemat biaya operasional dibandingkan pemeriksaan penunjang lainnya seperti CT-Scan, MRI dan pemeriksaan darah yang dilakukan di laboratorium.

Sebelum menentukan penyakit yang tampak dari gambar paru-paru di dalam citra rontgen dada, Dokter terlebih dahulu harus mengetahui atau menentukan batas area paru-paru tersebut. Tidak setiap citra rontgen dada memiliki gambaran paru-paru yang normal, sebagian menampilkan gambaran yang tidak normal seperti terlihatnya kabut putih dan atau perubahan morfologi paru-paru dikarenakan adanya proses penyakit.

Sebagai salah satu arsitektur dari Jaringan Syaraf Konvolusi yang dapat digunakan dalam melakukan segmentasi paru-paru, U-Net merupakan sebuah arsitektur yang terdiri atas susunan bagian konvolusi dan bagian dekonvolusi. Penelitian ini mencoba untuk melatih model pembelajaran mendalam dengan arsitektur CNN U-Net untuk mendeteksi area paru-paru dari sebuah gambar rontgen dada. Dari hasil percobaan yang kami lakukan model yang diusulkan tersebut dapat menunjukkan kemampuan dalam mengenali batas paru-paru dari gambaran paru-paru yang tidak normal atau berkabut. Performa dari model dihitung dengan mengukur nilai akurasi piksel dan nilai tumpang tindih, didapatkan nilai keduanya secara berurutan adalah 98,25% dan 94,54%.

Kata kunci: paru-paru, pembelajaran mendalam, rontgen, segmentasi.

ABSTRACT

Chest X-ray examination is the most commonly used supporting examination in the diagnosis of lung diseases. Besides being able to be done quickly and practically, X-ray examination is more cost-effective than other supporting examinations such as CT-Scan, MRI and blood tests performed in the laboratory.

Before determining the disease that appears from the image of the lungs in the chest X-ray image, the doctor must first know or determine the boundaries of the lung area. Not every chest X-ray image has a normal lung image, some display abnormal images such as the appearance of white haze and or changes in lung morphology due to disease processes.

As one of the Convolutional Neural Network architectures that can be used in segmenting the lungs, U-Net is an architecture that consists of a convolution part and a deconvolution part. This research tries to train a deep learning model with CNN U-Net architecture to detect lung area from a chest X-ray image. From our experimental results, the proposed model can demonstrate the ability to recognize lung boundaries from abnormal or foggy lung images. The performance of the model is calculated by measuring the pixel accuracy value and the overlap value, and the values are 98.25% and 94.54%, respectively.

Keyword: deep learning, lung, segmentation, x-ray.

BAB I

PENDAHULUAN

1.1. Latar Belakang Masalah

Berdasarkan laporan dari WHO tentang penyebab kematian terbesar di dunia didapatkan data bahwa tiga dari sepuluh penyebab kematian tertinggi adalah penyakit yang berhubungan dengan organ paru-paru. Penyakit paru obstruksi kronis (PPOK) berada pada urutan ke-3, infeksi pernafasan bawah (termasuk di dalamnya adalah pneumonia dan tuberkulosis) menempati urutan ke-4 dan penyakit kanker (trakea, bronkus dan paru-paru) berada pada urutan ke-6 (WHO, 2020). Dalam penegakan diagnosa penyakit paru-paru pemeriksaan dengan metode pencitraan paru-paru merupakan hal yang penting sebagai langkah dalam pemeriksaan penunjang. Sampai saat ini metode yang dapat digunakan dalam pencitraan paru-paru diantaranya adalah CT-Scan dan radiografi konvensional menggunakan *X-Ray*. Citra *X-Ray* dada (*thorax*) dipergunakan secara luas dan umum sebagai salah satu pemeriksaan penunjang untuk penegakan diagnosa penyakit paru-paru oleh dokter. Penyakit paru-paru seperti pneumonia, tuberkulosis, covid-19, kanker, tumor dan penyakit paru obstruksi kronis adalah contoh penyakit paru-paru yang dapat terlihat dari hasil citra *X-Ray* dada. Citra *X-Ray* dada dipergunakan oleh kedokteran sebagai pemeriksaan penunjang utama untuk penentuan diagnosa pneumonia (Fatimah, 2019). Di dalam citra *X-Ray* dada terdapat gambaran organ paru-paru yang dapat dibedakan dari organ sekitarnya, gambaran organ paru-paru terlihat lebih gelap daripada organ sekelilingnya.

Pada era saat ini telah banyak ilmuwan yang meneliti tentang citra medis atau dikenal dengan bidang biomedis, pengolahan citra pada bidang biomedis dilakukan dengan menggabungkan citra medis untuk klasifikasi, deteksi serta segmentasi menggunakan teknik yang salah satunya adalah metode *Deep Learning*. Hal tersebut berdasarkan publikasi (Litjens, 2017) algoritma-algoritma *Deep Learning* dengan sangat cepat berkembang menjadi metode pilihan dalam melakukan analisa terhadap citra-citra medis. Tidak sedikit proyek yang menambahkan fitur-fitur dari *Deep network* atau membandingkan antara CNN dengan *Machine learning* klasik yang memiliki fitur-fitur modifikasi. Hal tersebut dilakukan dalam aplikasi analisis terhadap citra toraks baik dari radiografi ataupun CT (*Computed tomography*) untuk deteksi, karakterisasi, dan klasifikasi nodul. Sebagai pemeriksaan radiologi yang paling umum, beberapa proyek menggunakan satu set besar citra radiografi (citra rontgen) beserta laporan teksnya dalam melakukan training sistem yang menggabungkan CNN untuk analisis citra dan RNN untuk analisis teks medis tersebut.

Segmentasi citra merupakan proses pembagian citra menjadi beberapa area yang homogen berdasarkan kriteria kemiripan tertentu antara level suatu piksel dengan piksel di sekitarnya. Tujuan dari segmentasi adalah untuk mendapatkan bentuk yang lebih sederhana dari citra untuk dapat dilakukan analisa pada tahap selanjutnya. Dari proses segmentasi akan menghasilkan batasan dari objek atau *Region of Interest* (ROI) dari sebuah citra. Terdapat beberapa jenis metode segmentasi citra mulai dari segmentasi berbasis aturan (*Rule-Based Segmentation*) hingga segmentasi menggunakan metode *Deep Learning*. Segmentasi dengan *Rule-*

Based Segmentation ini merupakan metode yang paling mudah untuk dilakukan karena cukup dengan menggunakan teknik *Computer Vision* konvensional untuk mengukur atau menentukan batas tepi dari paru-paru sehingga bagian dalam dari batas tepi tersebut dianggap sebagai bidang paru-paru. Pada beberapa tahun terakhir telah dilakukan penelitian-penelitian untuk melakukan segmentasi paru-paru dari citra hasil pemeriksaan radiologi, diantaranya adalah penelitian oleh (Yang et al. 2018) yang telah berhasil membuat sebuah sistem untuk mendeteksi batas area paru-paru dari citra *X-Ray* dada menggunakan SED (*Structured Edge Detection*) dengan akurasi segmentasi yang tinggi melebihi 90% namun masih gagal dalam menunjukkan kontur batas paru-paru yang masuk akal dari citra *X-Ray* dada yang abnormal. Berikutnya adalah penelitian yang dilakukan oleh (Zotin et al. 2019) yang mencoba untuk melakukan segmentasi batas paru-paru dari citra *X-Ray* dada sebelum melakukan klasifikasi, di dalam tahapan pra pemrosesannya dilakukan *Noise Suppression* dan *Contrast Enhancement* agar citra menjadi lebih tegas dan akurasi dari segmentasi meningkat, segmentasi batas paru dilakukan dengan tahapan *Otsu thresholding* dan *Edge detection*. Penelitian-penelitian tersebut menggunakan metode konvensional, metode konvensional belum dapat membedakan secara akurat antara objek dengan objek lainnya atau dengan latar belakang, hal ini dikarenakan metode tersebut hanya mempelajari representasi fitur secara dangkal (Wang et al., 2018). Hasil dari segmentasi menggunakan metode berbasis aturan tersebut dapat dilihat pada bab selanjutnya. Gambar tersebut merupakan hasil dari segmentasi yang dilakukan oleh (Yang et al. 2018) menggunakan teknik *edge detection*. Dapat dilihat pada gambar bahwa metode

yang dilakukan masih belum berhasil menentukan batas tepi dari paru-paru yang mengalami kondisi kerusakan cukup parah terlihat dari kabut atau bayang-bayang putih di area paru-paru tersebut.

Dengan berkembangnya teknologi GPU saat ini maka sistem *computer vision* dirancang menggunakan *deep neural network* (DNN) yang dilatih dengan jumlah data massif untuk menghasilkan akurasi yang lebih baik dibandingkan pendekatan konvensional. Data masukan diproses melalui lapisan-lapisan konvolusi yang dalam dimana penampakan fitur yang ada dipelajari apa adanya. Secara khusus jaringan saraf konvolusi (CNN) telah mendapatkan popularitas dalam analisis citra karena CNN mempertahankan hubungan spasial antar piksel gambar (Candemir et al. 2019). DNN dapat menandingi performa yang dihasilkan oleh pengamatan langsung atau penglihatan dokter spesialis.

Arsitektur *deep learning* seperti U-Net memiliki performa yang baik dalam pembuatan sistem untuk pendeteksian pada citra paru-paru. Arsitektur U-Net saat ini dipergunakan untuk membuat segmentasi citra biomedis. Segmentasi dilakukan dalam banyak sistem dan aplikasi yang berperan penting dalam analisa kondisi medis. Arsitektur U-Net pada penelitian (Asipong, 2021) digunakan dalam melakukan segmentasi paru-paru dari citra irisan hasil CT-scan dada penderita covid-19. Arsitektur U-Net dapat dimodifikasi hingga hanya tersisa 1 lapisan yang dapat meningkatkan waktu komputasinya tanpa secara signifikan mengurangi performa akurasi model tersebut.

Metode segmentasi berbasis aturan (*Rule-Based method*) yang diusulkan oleh (Zotin et al. 2019) untuk mendeteksi area paru-paru dari citra *X-Ray* dada telah menunjukkan akurasi yang baik dengan nilai *Jaccard Index* 0.915 (91.5%) dan nilai *Dice Similarity Coefficient* 0.955 (95.5%). Selain itu metode yang diusulkan oleh (Yang et al. 2018) telah berhasil menunjukkan *Jaccard Index* 0.952 (95.2%) untuk segmentasi paru-paru. Hasil matriks tersebut masih kurang 5% untuk dapat digunakan sebagai sistem otomatis penuh di bidang medis. Kelemahan pada sistem berbasis aturan tersebut juga disebutkan pada kedua penelitian di atas bahwa citra *X-Ray* yang terdapat gambaran paru-paru tidak normal belum berhasil dilakukan segmentasi terhadap area paru-parunya. Sebagai upaya dalam menyelesaikan masalah kegagalan segmentasi pada metode *Rule-Based Segmentation* dan untuk meningkatkan matriks segmentasinya maka diperlukan adanya pembelajaran fitur yang lebih mendalam dengan metode yang lain. Dengan mempertimbangkan hal tersebut maka penelitian ini bermaksud untuk membuktikan bahwa performa dan kemampuan segmentasi dari *Deep Convolutional Neural Network* (DCNN) dapat mengungguli metode segmentasi *Rule-Based Segmentation* yang hanya menggunakan teknik *Computer Vision* konvensional. Arsitektur yang akan digunakan adalah arsitektur U-Net yang dikenal baik dalam melakukan segmentasi pada citra biomedis.

1.2. Rumusan Masalah

- a. Bagaimana menentukan set hyperparameter yang optimal untuk segmentasi paru-paru dari citra *X-Ray* dada menggunakan *Deep CNN* arsitektur U-Net?
- b. Bagaimana memodifikasi model *Deep CNN* arsitektur U-Net untuk meningkatkan performa segmentasi paru-paru pada citra *X-Ray* dada?
- c. Berapa nilai akurasi piksel dan nilai irisan segmentasi paru-paru pada citra *X-Ray* dada menggunakan *Deep CNN* arsitektur U-Net?

1.3. Batasan Masalah

Batasan masalah dari penelitian ini adalah sebagai berikut:

- a. Penelitian ini akan melakukan segmentasi paru-paru dari citra *X-Ray* dada.
- b. Setiap citra *X-Ray* dada yang digunakan merupakan citra *X-Ray* dari dataset publik yaitu dataset Montgomery County (Jaeger, 2014).
- c. Citra *X-Ray* yang digunakan tidak dikhususkan pada kondisi paru-paru normal namun terdapat kelas paru-paru normal dan paru-paru dengan manifestasi tuberkulosis.
- d. Masing-masing file berukuran 2 hingga 7 megabyte dengan resolusi yang sama 4020 x 4892 piksel atau 4892 x 4020 piksel.

1.4. Tujuan Penelitian

Penelitian yang akan dilakukan memiliki tujuan sebagai berikut :

- a. Mengetahui bagaimana CNN dengan arsitektur U-Net dapat digunakan untuk melakukan segmentasi area paru-paru pada citra *X-Ray* dada.
- b. Mengetahui nilai akurasi piksel dan IoU CNN arsitektur U-Net untuk segmentasi paru-paru pada citra *X-Ray* dada.

1.5. Manfaat Penelitian

Hasil dari penelitian ini diharapkan akan memberikan manfaat terhadap pengembangan sistem informasi di dunia medis dalam hal:

- a. Dukungan sistem dalam penegakan diagnosa medis;
- b. Dapat menyelaraskan pemeriksaan dokter dengan perkembangan teknologi informasi;
- c. Untuk pengetahuan tentang algoritma dalam pendeteksian segmen paru-paru di dalam citra *X-Ray* dada;
- d. Menambah kemudahan dokter dalam mendiagnosa penyakit paru-paru;

1.6. Hipotesis

Arsitektur CNN U-Net dapat digunakan untuk mendeteksi dan segmentasi area paru-paru dari citra *X-Ray* dada dengan akurasi yang lebih baik dari metode segmentasi berbasis aturan (*Rule-Based Segmentation*).

BAB II


TINJAUAN PUSTAKA

2.1. Tinjauan Pustaka

Pada penelitian-penelitian terdahulu mengenai segmentasi batas area paru-paru dari citra *X-Ray* dada secara umum memiliki tujuan dan harapan yang sama yaitu untuk membantu dokter atau tim medis dalam melakukan analisa terhadap citra hasil pemeriksaan rontgen dada untuk mendeteksi berbagai macam penyakit paru-paru. Pendeteksian penyakit pada paru-paru tidak mungkin dapat dilakukan tanpa mengetahui batas anatomis dari organ paru-paru tersebut di antara beberapa organ lain di dalam sebuah gambaran *X-Ray* dada.

Pada penelitian yang dilakukan oleh (Yang et al. 2018) segmentasi paru-paru dilakukan menggunakan metode segmentasi berbasis aturan (*Rule-Based Segmentation*) dengan teknik *Computer Vision* konvensional. Inputan citra *X-Ray* dada pertama-tama dilakukan normalisasi dan dekomposisi terlebih dahulu, dari hasil normalisasi dicari mana bagian piksel yang termasuk paru-paru, tulang rusuk dan tulang dada. Setelah tulang rusuk dan tulang dada dikenali kemudian dilakukan pembagian garis tengah paru-paru untuk dapat mengenali paru-paru kanan dan paru-paru kiri. Tahapan-tahapan tersebut harus dilakukan karena paru-paru memiliki bentuk anatomis yang sangat bervariasi, termasuk di dalamnya ukuran jantung yang bervariasi dan atau patologi lainnya. Bidang paru-paru juga memiliki struktur yang tumpang tindih seperti pembuluh darah paru-paru itu sendiri,

klavikula dan juga tulang rusuk yang tidak membentuk batasan dari paru-paru. Percobaan tersebut berhasil menentukan batas paru-paru menggunakan *Structured Edge Detector*, dari hasil pendeteksian tepi tersebut maka dilakukan proses selanjutnya untuk membuat segmentasi paru-paru menggunakan *Watershed Transform* tradisional. Performa dari model tersebut diukur dengan menghitung nilai *Jaccard Index* yang mencapai angka 95.2% sedangkan untuk *Dice Similarity Coefficient (DSC)* mencapai angka 97.5%. Capaian tersebut dapat mengungguli setiap model segmentasi *Rule-Based* lainnya untuk paru-paru dengan kondisi normal, namun demikian model SED yang digunakan belum berhasil melakukan deteksi tepi dari paru-paru dengan kondisi yang tidak normal sehingga segmentasi tidak dapat dilakukan dengan kegagalan tersebut. Selain itu masih terdapat beberapa kontur paru-paru yang tidak rasional (Gambar 2.1).



Gambar 2. 1. Hasil segmentasi dari metode konvensional (Yang et al. 2018)

Penggunaan deep learning di dalam penelitian sebelumnya dilakukan dengan membuat arsitektur SegNet yang merupakan arsitektur encoder-decoder, untuk melakukan segmentasi pada gambar jalan dan gedung digunakan decoder berbasis VGG, encoder pada arsitektur ini identik dengan layer konvolusi pada VGG16, SegNet dapat menunjukkan performa bagus dengan efisiensi waktu karena hanya menyimpan hasil dari proses max-pooling yang mengindikasikan feature maps dan digunakan untuk proses decodernya (Badrinarayanan et al. 2017). Deep Convolutional Neural Network dengan tambahan langkah pre-trained menggunakan gambar non-radiologi dapat meningkatkan akurasi pada klasifikasi gambar *X-Ray* dada, arsitektur dengan pre-trained ini dapat mengklasifikasi gambar *X-Ray* dada dengan memanfaatkan gambar umum dari ImageNet untuk proses trainingnya dan kemudian dilakukan fine-tuned menggunakan augmentasi dari gambar *X-Ray* dada (Rajkomar et al. 2017).

Percobaan segmentasi paru-paru dari citra *X-Ray* dada juga pernah dilakukan menggunakan CNN arsitektur AlexNet (Souza, 2019). Pada percobaan tersebut arsitektur AlexNet menunjukkan performa yang sangat kuat dalam melakukan segmentasi paru-paru. Pengenalan paru-paru dengan sangat presisi pada paru-paru kondisi normal. Penelitian tersebut mencoba melakukan rekonstruksi terhadap hasil segmentasi paru-paru yang tidak normal menggunakan CNN berbasis ResNet. Dapat disimpulkan bahwa rekonstruksi tersebut berhasil memperbaiki hasil segmentasi dari paru-paru yang tidak normal. Selain digunakan dalam melakukan segmentasi paru-paru dari citra *X-Ray* dada, CNN juga pernah digunakan untuk melakukan segmentasi paru-paru dari citra CT-Scan dada. Metode

yang diusulkan dapat melakukan segmentasi dengan waktu komputasi yang lebih rendah dan berhasil melakukan segmentasi paru-paru dengan tingkat kelainan tertentu (Xu, 2019). Yang tidak kalah penting adalah bahwa metode CNN tersebut tidak memerlukan pekerjaan rekayasa fitur secara manual.

CNN dengan arsitektur U-Net pernah digunakan dalam melakukan segmentasi paru-paru pada citra CT-scan dada dari pasien covid-19. Model tersebut berhasil menampilkan performa yang mengesankan dengan nilai akurasi 93.76% dan waktu pelatihan 9288 detik (Asipong, 2021). Di dalam melakukan pelatihan U-Net untuk segmentasi paru-paru dari citra CT-scan dada masih membutuhkan waktu komputasi yang cukup tinggi, sehingga penelitian tersebut mencoba untuk mengurangi jumlah lapisan dari arsitektur U-Net, pengurangan lapisan dimulai dari hanya 1 lapisan yang terdiri dari 4 *Deep Fully Convolutional Neural Network* kemudian 2 lapisan dan 3 lapisan. Pengurangan jumlah lapisan U-Net terbukti dapat menghemat waktu komputasi mencapai 84.76% pada U-Net 1 lapisan. Pada penelitian (Nishio et al. 2021) segmentasi paru-paru dari gambar CXR dengan temuan abnormal parah dapat dilakukan dengan baik menggunakan CNN yang dioptimasi menggunakan optimasi Bayesian. Optimasi tersebut menunjukkan bahwa penggunaan normalisasi batch dapat meningkatkan akurasi segmentasi secara signifikan. Tidak hanya normalisasi batch, namun tuning hiperparameter pada deep learning dapat meningkatkan kinerja dari model tersebut.

Berdasarkan beberapa literatur di atas CNN dapat menunjukkan performa yang baik dalam tugas segmentasi citra biomedis. Terdapat beberapa arsitektur

CNN yang dapat digunakan namun U-Net adalah arsitektur yang disiapkan dan dikembangkan untuk segmentasi citra biomedis sejak awal ditemukannya. Arsitektur U-Net juga dikatakan tidak membutuhkan data latih yang terlalu banyak, oleh karena itu penelitian ini akan mencoba melakukan segmentasi paru-paru dari citra *X-Ray* dada dengan dataset Montgomery County yang hanya terdiri dari 138 pasang citra *X-Ray* dada dengan anotasi (*Ground Truth*) paru-parunya. Penelitian ini akan melihat bagaimana hasil dari segmentasi U-Net terhadap citra *X-Ray* dada dengan kondisi paru-paru yang tidak normal atau memiliki kelainan tertentu.



2.2. Keaslian Penelitian

Tabel 2.1. Matriks literatur review dan posisi penelitian
Segmentasi Paru-Paru dari Citra *X-Ray* Dada Menggunakan CNN dengan Arsitektur U-Net

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kekurangan	Perbandingan
1	Lung Field Segmentation in Chest Radiographs From Boundary Maps by a Structured Edge Detector	Yang, Wei Liu, Yunbi Lin, Liyan Yun, Zhaoqiang Lu, Zhentao Feng, Qianjin Chen, Wufan; IEEE journal of biomedical and health informatics, 2018, (Q1)	Mengembangkan metode yang praktis dan berguna untuk segmentasi bidang paru-paru secara otomatis pada citra <i>X-Ray</i> dada. Pengenalan batas paru-paru menggunakan SED (Structured Edge Detection).	Penelitian tersebut dapat menunjukkan metode segmentasi paru-paru yang performanya dapat mengungguli metode segmentasi lain dan dapat memenuhi kebutuhan praktis yang realtime. Hasil penelitiannya menunjukkan bahwa segmentasi bidang paru-paru dapat dilakukan menggunakan SED sehingga metode tersebut dapat diadopsi di dalam	Paru-paru memiliki bentuk anatomis yang sangat bervariasi termasuk di dalamnya ukuran jantung atau patologi lainnya. Bidang paru-paru juga memiliki struktur yang tumpang tindih seperti pembuluh darah paru-paru, klavikula dan tulang rusuk yang tidak membentuk batas paru-paru. Batas tepi yang tegas dari tulang rusuk dan klavikula menyebabkan	Pada penelitian tersebut algoritma yang digunakan untuk segmentasi paru-paru adalah SED (Structured Edge Detection) yang merupakan algoritma tradisional dalam pengolahan dan pengenalan citra. Pada penelitian yang akan dilakukan menggunakan metode <i>Deep Learning</i> dengan arsitektur CNN U-Net.

Tabel 2. 1. (Lanjutan)

				menyederhanakan pendekatan analisis citra <i>X-Ray</i> dada.	kontur paru-paru tidak akurat di dalam beberapa pendekatan segmentasi; Metode ini hanya berhasil untuk paru-paru normal dan bersih, namun gagal untuk paru-paru dengan kondisi rusak / terlihat berkabut.	
2	Lung boundary detection for chest <i>X-Ray</i> images classification based on GLCM and probabilistic neural networks	Zotin, Aleksandr Hamad, Yousif Simonov, Konstantin Kurako, Mikhail Procedia Computer Science, 2019. (Terindeks Scopus)	Merancang sebuah metode segmentasi dan klasifikasi batas paru-paru dan deteksi abnormal dari citra <i>X-Ray</i> dada.	Penelitian tersebut terdiri dari 3 tahap utama yaitu peningkatan kualitas gambar <i>X-Ray</i> menggunakan noise reduction dan contrast adjustment, kedua adalah melakukan segmentasi dan ketiga adalah melakukan klasifikasi dari hasil segmentasi paru-paru tersebut.	Pemanfaatan hasil dari segmentasi paru-paru dapat digunakan untuk input pada klasifikasi. Hasil dari performa klasifikasi pada metode ini masih belum dapat digunakan dalam sistem otomatis.	Pada penelitian tersebut segmentasi paru-paru dilakukan menggunakan tahapan Otsu's Thresholding kemudian Edge detection. Hasil dari segmentasi digunakan sebagai input untuk klasifikasi menggunakan PNN dan ekstraksi fitur menggunakan GLCM. Pada penelitian yang akan dilakukan tidak dilakukan klasifikasi namun hanya sampai segmentasi batas paru-paru menggunakan CNN.

Tabel 2. 1. (Lanjutan)

3	An automatic method for lung segmentation and reconstruction in chest X-ray using deep neural networks	Souza et al. Computer Methods and Programs in Biomedicine (Q1), 2019.	Melakukan segmentasi paru-paru dari citra <i>X-Ray</i> dada menggunakan metode CNN dan melakukan rekonstruksi terhadap area paru-paru hasil segmentasi dari paru-paru yang memiliki tingkat kelainan tertentu menggunakan CNN.	Penggunaan CNN sangat kuat di dalam tugas segmentasi paru-paru yang normal kondisinya. Namun demikian masih terdapat kekurangan di dalam segmentasi paru-paru dengan tingkat kelainan tertentu. Sebagai tahapan selanjutnya diperlukan rekonstruksi menggunakan CNN untuk memperbaiki segmentasi dari paru-paru yang memiliki tingkat kelainan tertentu. CNN berbasis ResNet dapat digunakan dalam tahapan rekonstruksinya.	Metode yang dilakukan tersebut memiliki keterbatasan bahwa rekonstruksi tidak selalu menjamin peningkatan kuantitas dari segmentasi. Terkadang false positive dimasukkan dan true positive malah dihilangkan dari hasil segmentasi. Diharapkan untuk peneliti selanjutnya menggunakan metode optimasi seperti algoritma evolusi dalam meningkatkan arsitektur CNN.	Penelitian yang akan dilakukan menggunakan CNN berbasis U-Net sedangkan pada penelitian tersebut menggunakan CNN berbasis AlexNet.
4	Automatic lung segmentation on chest x-rays using self-attention deep neural network	Sensors by MDPI (Q1). 2021 Kim, Minki	Melakukan eksperimen untuk mengetahui performa dari metode segmentasi paru-paru berbasis deep learning.	Penerapan attention modul tidak meningkatkan waktu pelatihan secara signifikan.		Pada penelitian yang akan dilakukan tidak menerapkan attention modul di dalam pelatihan model.

Tabel 2. 1. (Lanjutan)

		Lee, Byoung Dai	Menerapkan modul untuk meningkatkan kinerja deep learning yang dipilih.			
5	Lung segmentation on chest <i>X-Ray</i> images in patients with severe abnormal findings using deep learning	Nishio, Mizuho, Fujimoto, Koji, Togashi, Kaori International Journal of Imaging Systems and Technology, 2021	Penelitian tersebut bertujuan untuk memanfaatkan deep learning guna melakukan segmentasi paru-paru dari citra <i>X-Ray</i> dada dengan temuan abnormal yang parah. Untuk memvalidasinya dibuat sebuah database <i>X-Ray</i> dada untuk segmentasi paru-paru, yang mana di dalamnya termasuk citra <i>X-Ray</i> dada dengan temuan abnormal yang parah dan hasil	Peneliti tersebut berhasil membangun sebuah database <i>X-Ray</i> dada yang mengandung temuan abnormal parah dan berguna untuk membangun sistem segmentasi paru-paru dari citra <i>X-Ray</i> dada. Sistem yang dibangun berhasil dengan baik melakukan segmentasi paru-paru dari citra <i>X-Ray</i> dada yang terdapat temuan abnormal parah. Peningkatan dari akurasi model yang dibangun didapatkan dari penggunaan	Kelemahan yang muncul dari penelitian tersebut adalah kesulitan ketika membuat segmentasi manual terhadap paru-paru dari citra <i>X-Ray</i> dada yang berjumlah banyak. Selanjutnya peneliti hanya mencoba optimasi Bayesian terhadap satu tugas segmentasi, padahal optimasi Bayesian dapat dipergunakan dalam bermacam-macam pekerjaan seperti klasifikasi, saran dari peneliti adalah untuk mencoba optimasi Bayesian ke tugas-tugas dan model-model	Pada penelitian tersebut dilakukan optimasi CNN dengan menggunakan optimasi Bayesian, sedangkan pada penelitian yang akan dilakukan optimasi akan dilakukan dengan tuning hyperparameter learning rate.

Tabel 2. 1. (Lanjutan)

			<p>segmentasinya yang dilakukan oleh ahli radiologi. Tujuan kedua adalah untuk menerapkan optimasi Bayesian dalam mengoptimalkan hiperparameter yang muncul di dalam model deep learning mereka.</p>	<p>optimasi Bayesian dan modifikasi model CNN.</p>	<p>lainnya. Selain itu tidak seluruh hiperparameter pada model CNN dioptimasi pada pelatihan tersebut, sebagai contohnya faktor-faktor seperti ukuran dari citra input, atau penggunaan dari pra pemrosesan citra tidak dikaji, karena perubahan pada ukuran citra dapat mengakibatkan peningkatan biaya komputasi, namun akan sangat memungkinkan untuk melakukan segmentasi paru-paru dengan lebih tepat pada citra berukuran besar. Hubungan hiperparameter seharusnya dapat dievaluasi pada penelitian-penelitian selanjutnya.</p>	
--	--	--	------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------	----------------------------------------------------	----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------	--

Tabel 2. 1. (Lanjutan)


6	Lung Segmentation Using <i>Deep Learning</i>	Sri, S. Vinita Kavya, S.P., Asian Journal of Applied Science and Technology, 2021	Penelitian tersebut bertujuan untuk mengembangkan model segmentasi paru-paru dari citra <i>X-Ray</i> dada menggunakan metode transfer learning dalam pelatihannya.	Percobaan untuk segmentasi paru-paru dengan menggunakan CNN berhasil dilakukan dengan akurasi 97,63% dan koefisien dadu 0.9544. Untuk menghemat waktu dalam pelatihan model dilakukan transfer learning menggunakan encoder VGG-11 dengan pre-trained ImageNet.	Peningkatan akurasi model yang dikembangkan menggunakan VGG-11 sebagai encoder dari metode transfer learning tidak lebih dari 1%.	Perbedaan dari penelitian tersebut dengan yang akan dilakukan adalah pada dataset yang digunakan dan penggunaan VGG-11 sebagai encoder untuk transfer learning.
7	A <i>Deep Learning</i> Method for Lung Segmentation on Large Size Chest <i>X-Ray</i> Image	Huynh, H.T. Anh, V.N.N IEEE International Conference on Research, Innovation and Vision for the Future, 2019.	Penelitian tersebut mencoba untuk melakukan segmentasi paru-paru dari gambar <i>X-Ray</i> dada beresolusi tinggi yaitu 3728 x 3940 piksel. Metode yang dilakukan dengan menggabungkan CNN untuk segmentasi dan dilanjutkan dengan	Metode hybrid yang menggabungkan CNN dengan metode tradisional tersebut dapat menunjukkan performansi yang lebih bagus dibandingkan dengan metode tradisional dalam segmentasi paru-paru.	Batas-batas wilayah paru-paru dari metode yang diusulkan tidak sehalus metode lainnya karena jaringan mengklasifikasikan setiap piksel, tetapi dari pengetahuan terbaik, batas-batas yang sebenarnya tidak mulus. Meskipun metode segmentasi terkomputerisasi kami memiliki kesepakatan	Perbedaan penelitian tersebut dengan penelitian yang akan dilakukan adalah pada metode yang digunakan. Penelitian tersebut menggunakan gabungan antara CNN dengan metode tradisional sedangkan penelitian yang akan dilakukan menggunakan CNN arsitektur U-Net.

Tabel 2. 1. (Lanjutan)

			<p>pemrosesan citra tradisional.</p>		<p>yang sangat baik dengan metode manual standar emas metode manual standar emas, masih ada FN dan FP sesekali yang terutama disebabkan oleh kepadatan yang sama dari yang lain daerah atau daerah paru-paru dengan kelengkungan yang tinggi.</p> <p>Segmentasi paru-paru dari citra <i>X-Ray</i> dada dengan ukuran resolusi tinggi masih menjadi tantangan.</p>	
8	<p>Coronavirus Infected Lung CT Scan Image Segmentation using <i>Deep Learning</i></p>	<p>Asipong, K, Gabbualoy, S, Phasukkit, P, 2021</p>	<p>Penelitian tersebut bertujuan untuk melakukan segmentasi citra medis dari gambar irisan CT-scan paru yang terinfeksi Covid-19 menggunakan Deep Convolutional Neural Network</p>	<p>Arsitektur U-Net dapat dimodifikasi hingga hanya menggunakan 1 layer untuk dapat mendeteksi segmen paru-paru pada citra CT Scan hingga mencapai akurasi 92.46% yang hampir menyerupai akurasi dari U-Net asli dengan nilai 93.76%</p>	<p>Untuk penelitian kedepannya diperlukan adanya pengaturan algoritma secara matematis terhadap model deep learning dan pemrosesan proyeksi axis citra dengan banyak irisan (citra CT scan)</p>	<p>Perbedaan penelitian tersebut dengan penelitian yang akan dilakukan adalah penelitian tersebut menggunakan dataset citra CT-Scan dada sedangkan pada penelitian yang akan dilakukan menggunakan dataset citra <i>X-Ray</i> dada.</p>

Tabel 2. 1. (Lanjutan)

			(DNN) dengan teknik AI yang dikembangkan dan dimodifikasi melalui arsitektur U-Net.	namun dapat mempersingkat waktu pelatihan 84.76%.	agar performa segmentasi meningkat.	
--	--	--	-------------------------------------------------------------------------------------	---------------------------------------------------	-------------------------------------	--



2.3. Landasan Teori

2.3.1. Dataset


Dataset berupa citra *X-Ray* dada didapatkan dari program pengendalian tuberkulosis pada Departemen Kesehatan dan Layanan Kemanusiaan Montgomery County, MD, AS. Dataset tersebut sudah berupa dataset publik yang bisa diunduh melalui situs-situs penyedia dataset publik seperti kaggle, mdai, dan lain-lain.

Dataset berupa gambar atau citra dari hasil foto rontgen dada yang menggambarkan kondisi organ paru-paru dan jantung. Area dan batas-batas dari organ paru-paru dibuat secara manual di dalam gambar terpisah yang terdiri dari batas paru-paru kanan dan paru-paru kiri. Ukuran dari gambar segmentasi paru-paru manual disamakan dengan ukuran gambar dari hasil foto rontgen dadanya.

Publikasi tersebut (Jaeger et al. 2014) menyediakan database dari dua sumber lokasi yang berbeda. Pekerjaan tersebut dilakukan guna memberikan dukungan atas upaya dunia dalam mengatasi ancaman kesehatan global salah satunya adalah Tuberkulosis. Para ahli mencoba untuk membuat sebuah sistem yang mempermudah dunia kesehatan dalam mendeteksi tuberkulosis melalui hasil citra dari pemeriksaan penunjang diagnostik, seperti diantaranya adalah pemeriksaan radiologi. Untuk mendeteksi keberadaan bakteri tuberkulosis di dalam paru-paru diperlukan keahlian untuk menganalisis gambar citra paru-paru dari citra *X-Ray* dada, namun pada kondisi saat ini keberadaan ahli yang menganalisa radiologi sangat terbatas sehingga masih sangat diperlukan pengembangan sistem bantuan diagnosis dari komputer.

Dataset yang pertama dikumpulkan dari Montgomery County, Maryland, AS dengan bekerjasama bersama Departemen Kesehatan dan Layanan Kemanusiaan. Dataset tersebut berisikan 138 rontgen dada dari program skrining Tuberkulosis yang terdiri atas 80 kasus normal dan 58 kasus dengan TB. Untuk dataset kedua dikumpulkan dari Rumah Sakit Rakyat Shenzhen, Sekolah Tinggi Kedokteran Guangdong, Shenzhen, Tiongkok. Gambaran rontgen dada dikumpulkan dari klinik rawat jalan dalam jangka waktu 1 bulan yang terdiri dari 662 rontgen dada dengan 326 diantaranya adalah kasus normal dan 336 kasus dengan TB termasuk anak-anak.

Kedua dataset yang disediakan oleh perpustakaan kedokteran nasional AS tersebut dapat diakses dengan melakukan permohonan terlebih dahulu, namun untuk dataset dari MC dapat diakses langsung melalui MD.ai (<https://md.ai>) dengan membuat akun terlebih dahulu. MD.ai merupakan sebuah platform yang didirikan oleh para dokter dari Harvard/Duke/Columbia guna mendukung percepatan penerapan AI di dunia kedokteran dengan berfokus pada pencitraan medis. Dataset MC tersebut telah disediakan sejak awal bersama dengan masking area paru-paru yang dapat dipergunakan untuk melatih model segmentasi citra.



Gambar 2. 2. Tampilan dari Sebagian dataset citra X-Ray dada.

2.3.2. Deep Learning

Pada dasarnya *Deep Learning* merupakan sebuah pengembangan dari neural network yang merupakan salah satu dari sekian banyak tipe-tipe machine learning. Seperti halnya machine learning, deep learning memungkinkan komputer untuk belajar tanpa harus secara khusus diprogram, deep learning bisa juga diartikan sebagai turunan dari neural network yang memiliki banyak sekali hidden layer, yang di dalamnya terdapat banyak sekali neuron digital dengan jumlah koneksi berbobot yang sangat banyak dan dapat diubah selama proses pembelajaran atau training (Moses, 2021).

2.3.3. CNN

Jaringan Konvolusi (Convolutional Network) pada umumnya dipergunakan dalam sistem klasifikasi yang menghasilkan output label kelas tunggal pada sebuah citra. Klasifikasi dalam bidang biomedis memerlukan output yang dapat menunjukkan lokalisasi dari area yang diinginkan, sehingga dalam hal ini klasifikasi diterapkan pada setiap pixel dari citra. Diperlukan ribuan citra untuk dapat melakukan klasifikasi pada bidang biomedis yang biasanya tidak mudah untuk mendapatkannya.

CNN merupakan salah satu Deep Neural Network yang paling umum dipergunakan untuk analisis citra medis. CNN terdiri dari neuron-neuron yang tersusun di dalam banyak lapisan 2D yang masing-masing memiliki fungsi tersendiri (Moses, 2021). Diperlukan dataset yang cukup besar untuk melatih sebuah Deep CNN dari awal, namun hal ini dapat diatasi dengan menggunakan jaringan pre-trained dengan dataset besar yang sudah terlabeli secara generik seperti ImageNet yang memiliki 14.197.122 gambar berlabel dengan berbagai macam objek. Begitu model tersebut terlatih dengan baik, maka lapisan konvolusinya akan berisikan data fitur yang berhubungan dengan pendeteksian bentuk-bentuk umum. Untuk dapat mendeteksi fitur dengan level tinggi pada citra *X-Ray* dada maka hanya diperlukan sedikit pelatihan pada layer-layer yang dipilih.

CNN terinspirasi dari proses biologi yang mana pola hubungan antar neuron menyerupai organisasi visual cortex pada binatang (Suyanto et al. 2019). Arsitektur CNN tersusun dari beberapa lapisan yaitu lapisan masukan (input layer), lapisan keluaran (output layer), dan sejumlah lapisan tersembunyi (hidden layer) yang

secara umum berisikan convolutional layers, pooling layers, normalization layers, ReLu layer, fully connected layers dan loss layer.

2.3.3.1. Convolution Layer

Lapisan konvolusi ini adalah blok bangunan inti dari CNN dimana sebagian besar komputasi dilakukan pada lapisan ini. Setiap citra input akan dibaca melalui blok filter yang ditentukan, seluruh bidang reseptif ditelusuri dengan tumpang tindih parsial, sehingga semua neuron akan berbagi bobot (weight sharing). Umumnya sebuah arsitektur CNN menggunakan lebih dari 1 filter atau kernel. Filter berjalan menyusuri seluruh piksel dengan lebar langkah yang harus ditentukan, pada umumnya CNN menggunakan lebar langkah atau stride = 1 dengan zero padding sebesar:

$$P = ((F - 1))/2$$

dimana P adalah ukuran padding dan F adalah ukuran bidang reseptif atau tingkat spasial yang bisa dikatakan sama dengan ukuran dari filter.

Konvolusi pada dasarnya hanya merupakan sebuah *dot product* antara filter dengan sebuah bidang reseptif kecil pada citra masukan. Bidang-bidang reseptif neuron saling tumpang tindih secara parsial. Pergeseran filter dengan lebar langkah atau stride yang ditentukan akan bergeser menyusuri hingga seluruh bidang reseptif dari citra tercakup.

2.3.3.2. Pooling Layer

Lapisan ini memiliki peran dalam menjaga ukuran data ketika dilakukan konvolusi dengan mereduksi sampel (*downsampling*). Data yang telah direduksi dapat lebih mudah untuk dikelola dan lebih mudah dalam mengontrol *overfitting*.

Proses *pooling* yang umum digunakan adalah *max-pooling* dan *average-pooling*. *Pooling* dilakukan dengan cara memilih nilai maksimum atau nilai rata-rata dalam suatu area tertentu. Pada penggunaannya metode *max pooling* dapat memberikan performa yang lebih baik dibandingkan dengan *average pooling*, *L2-norm pooling* atau teknik *pooling* lainnya.

2.3.3.3. *Normalization Layer*

Nilai-nilai pada citra masukan memiliki rentang yang signifikan, dengan adanya lapisan ini perbedaan rentang-rentang nilai yang signifikan dapat diatasi. Lapisan normalisasi telah banyak diusulkan oleh para peneliti, namun penggunaan dari lapisan ini relatif jarang dikarenakan dampaknya yang tidak begitu besar, bahkan bisa jadi tidak ada sama sekali.

2.3.3.4. *Activation Layer*

Lapisan aktivasi atau bisa juga disebut lapisan ReLu (Rectified Linear Units) diterapkan guna mengaplikasikan aktivasi $f(x) = \max(0, x)$. Fungsi aktivasi ini berguna untuk meningkatkan sifat nonlinearitas dari fungsi keputusan dan jaringan secara keseluruhan tanpa mempengaruhi bidang-bidang reseptif pada lapisan konvolusi. Tidak hanya fungsi aktivasi ReLu yang dapat digunakan pada lapisan ini, terdapat juga fungsi lain seperti salah satu contohnya adalah fungsi tangen hiperbolik dengan $f(x) = \tanh(x)$, $f(x) = |\tanh(x)|$, atau $f(x) = \frac{1}{1 + e^{-x}}$.

2.3.3.5. *Fully Connected Layer*

Menyerupai dengan yang ada pada Multi Layer Perceptron (MLP), lapisan FCN ini terhubung secara penuh dimana setiap neurons memiliki koneksi penuh

kepada semua aktivasi dalam lapisan sebelumnya. Model aktivasinya juga sama dengan MLP yaitu komputasi dilakukan menggunakan satu perkalian matriks yang diikuti dengan bias offset.

2.3.3.6. Loss Layer


Lapisan ini merupakan lapisan yang terakhir dari CNN, dimana lapisan ini menentukan bagaimana pelatihan dari model tersebut memberikan penalti atas penyimpangan antara hasil prediksi dan labelnya. Terdapat beberapa variasi loss function, diantaranya adalah softmax loss yang digunakan untuk memprediksi satu dari sejumlah kelas yang saling eksklusif, selain itu ada sigmoid cross-entropy loss yang digunakan untuk memprediksi sejumlah nilai probabilitas dalam interval $[0, 1]$, dan juga ada euclidean loss yang digunakan untuk regresi nilai kontinu.

2.3.4. U-Net

Sebagai salah satu dari sekian banyak arsitektur CNN, U-Net digunakan untuk segmentasi citra secara umum. Sejak awal ditemukannya U-Net dikembangkan berdasarkan jaringan saraf konvolusi tradisional yang disiapkan untuk memproses gambar biomedis. Pada umumnya CNN dipergunakan dalam tugas-tugas klasifikasi dengan output 1 label sebagaimana dalam deteksi penyakit, namun U-Net lebih dari sekedar membedakan apakah sebuah citra input terklasifikasi sebagai normal atau tidak normal akan tetapi juga melokalisasi area kelainan tersebut. U-Net didedikasikan untuk memecahkan masalah segmentasi dan dapat melokalisasi serta membedakan batas dengan melakukan klasifikasi pada setiap piksel, dengan demikian antara input dengan output memiliki ukuran yang sama.

Sebagai model pembelajaran yang mendalam, U-Net terdiri dari arsitektur encoding-decoding. Lebih lanjut, U-Net terdiri dari dua jenis jalur: jalur analisis untuk agregasi konteks dan jalur sintesis yang memanfaatkan informasi semantik dan spasial dari lapisan dalam U-Net. Karakteristik yang paling penting dari U-Net adalah adanya koneksi jalan pintas (*skip connection*) antara jalur analisis dan jalur sintesis pada resolusi yang sama. Koneksi U-Net ini memungkinkan jalur sintesis untuk memanfaatkan fitur resolusi tinggi dari jalur analisis (Nishio et al. 2021).

Perbedaan yang sangat mendasar dari U-Net dengan CNN standar adalah tidak adanya lapisan *fully connected (dense layer)* pada U-Net yang mana lapisan tersebut digunakan untuk menentukan kelas gambar secara utuh pada CNN. Tidak adanya *dense layer* pada U-Net tersebut menjadikan U-Net disebut juga sebagai arsitektur konvolusi penuh. Poin penting dari arsitektur U-Net ini adalah dirancang untuk tugas segmentasi khususnya pada bidang biomedis dan dapat mencapai hasil yang bagus hanya dengan menggunakan data yang berjumlah sedikit.



Gambar 2. 3. Diagram Arsitektur U-Net dimulai dari kiri sebagai input dan ke kanan sebagai output

2.3.4.1. Encoder

Dapat dilihat pada bagian kiri dari gambar arsitektur tersebut bahwa bagian yang menurun disebut dengan encoder atau *contracting path* yang mana urutannya mengikuti jaringan konvolusi pada umumnya. Bagian ini melakukan pengulangan dengan konvolusi 3 x 3, setiap konvolusi diikuti dengan aktivasi ReLu dan max-pooling 2 x 2 dan pergeseran (*stride*) 2 untuk *downsampling*.

2.3.4.2. Decoder

Pada bagian kanan arsitektur dapat disebut sebagai bagian *decoder* atau *upsampling*. Setelah melalui bagian *bottleneck* (bagian paling bawah) pada arsitektur tersebut, hasil dari *feature maps* digabungkan dengan hasil konvolusi *upsampling* atau *transposed convolution*. Terdapat 4 (empat) blok konvolusi dan konkatenasi (penggabungan) dengan hasil akhirnya adalah output berupa masking paru-paru.

2.3.5. Segmentasi

Begitu banyaknya penyakit paru-paru yang dapat dideteksi menggunakan pemeriksaan *X-Ray* dada bahkan Covid-19 yang sangat mewabah pun dapat dideteksi melalui gambaran paru di dalam *X-Ray* tersebut. Sehubungan dengan jenis penyakit paru-paru yang menular maka pemeriksaan *X-Ray* dada ini dapat membantu mempercepat penentuan kebutuhan kamar isolasi dari pasien dengan penyakit paru-paru yang menular.

Segmentasi pada analisis citra berfungsi untuk memberikan highlight terhadap area yang diharapkan. Segmentasi yang dilakukan sebelum klasifikasi dapat meningkatkan akurasi dari model klasifikasi (Zotin et al, 2019). Semakin

tinggi akurasi dari segmentasi pada citra medis akan meningkatkan kemampuan dalam identifikasi penyakit lebih tepat.

Citra *X-Ray* dada merupakan gambaran dari seluruh organ yang ada di dalam area penangkapan sehingga tidak hanya paru-paru saja yang terdapat di dalamnya. Lengan pasien, sebagian tulang rusuk, tulang dada, pembuluh aorta dan organ jantung merupakan latar belakang yang tidak diperlukan dalam klasifikasi penyakit paru-paru. Citra *X-Ray* dada yang tersegmentasi akan sangat membantu dalam diagnosis medis oleh seorang dokter spesialis. Dengannya, informasi dari segmen paru-paru yang didapatkan dapat digunakan untuk mengevaluasi ukuran dan fitur paru-paru yang berguna dalam asesmen medis.

Banyak metode yang diusulkan dalam menentukan ROI di dalam mendeteksi adanya kelainan tertentu di dalam paru-paru seperti tumor, TB, kavitasi (rongga), opasitas dan konsolidasi. Sebuah citra *X-Ray* digunakan secara utuh dan menyeluruh di dalam proses pelatihan, keberadaan organ lain yang tidak diperlukan di dalam *X-Ray* dada dapat menimbulkan adanya noise dan False Positive (FP) (Agrawal, 2023). Beberapa metode di dalam segmentasi dikelompokkan ke dalam beberapa kategori besar yaitu Rule-Based, Pixel classification-based, Deformable-based dan Hybrid methods. U-Net yang dikembangkan oleh Olaf Ronneberger et al (2015) untuk segmentasi citra biomedis merupakan salah satu arsitektur yang banyak digunakan dalam bidang medis. U-Net adalah "Fully Convolutional Network" yang menggunakan pendekatan segmentasi semantik. Tidak seperti *Deep Learning* secara umum, arsitektur U-Net ini telah terbukti melakukan segmentasi secara akurat dan cepat meskipun dengan jumlah dataset yang terbatas. Faktor

tersebut sangat penting mengingat tidak mudahnya untuk mendapatkan volume yang cukup besar dari data latih citra di bidang medis.

Object Identification / Identifikasi Objek adalah pengenalan sebuah instansiasi (instance) dari sebuah objek. Contohnya identifikasi wajah, identifikasi sidik jari atau identifikasi kendaraan tertentu. Object Detection / Deteksi Objek : sebuah citra dipindai untuk kondisi atau tujuan tertentu. Sebagai contohnya deteksi sel atau jaringan yang abnormal dalam citra biomedis, deteksi kendaraan di dalam sebuah sistem jalan tol otomatis. Deteksi objek ini membantu membedakan antar objek satu dengan lainnya namun tidak membantu mengidentifikasi dari batas-batas objek. Segmentation / Segmentasi : Berbeda dari object detection, segmentasi membantu membedakan area terbatas dari area sekitarnya, di dalam kasus segmentasi paru-paru pada *X-Ray* dada dilakukan untuk pemisahan paru-paru dari organ sekitarnya.

BAB III

METODE PENELITIAN

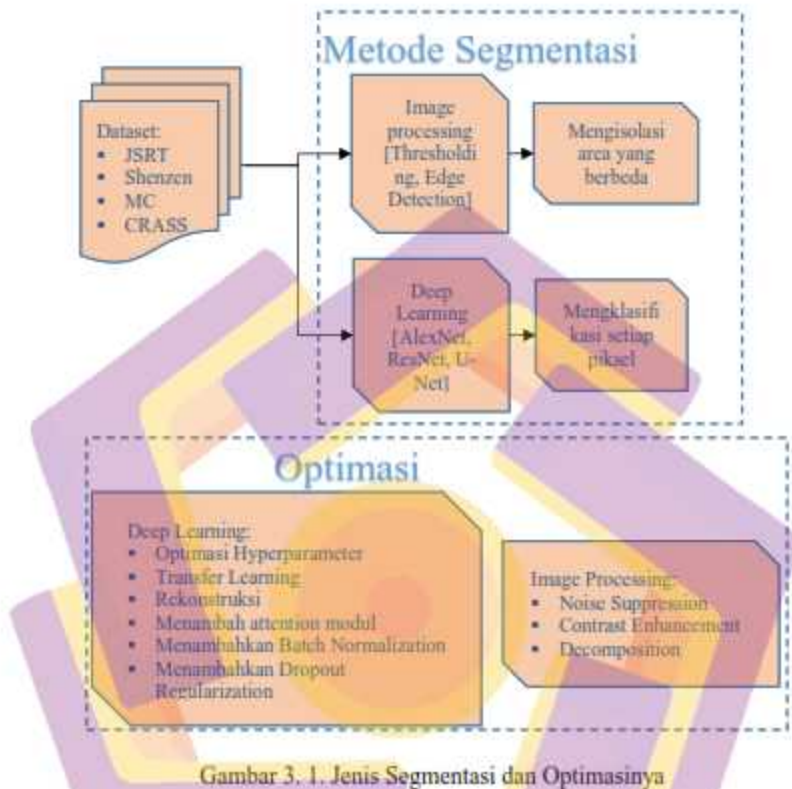
3.1. Jenis, Sifat, dan Pendekatan Penelitian

Penelitian yang akan dilakukan menggunakan metode pendekatan kuantitatif. Jenis penelitian yang akan dilakukan termasuk ke dalam jenis penelitian eksperimen. Penelitian eksperimen adalah penelitian yang dapat menguji hipotesis mengenai hubungan sebab akibat.

Dengan melihat permasalahan yang masih dialami oleh beberapa penelitian sebelumnya dalam melakukan segmentasi paru-paru dari citra X-Ray dada maka penelitian yang akan dilakukan mencoba untuk melakukan segmentasi dengan metode yang berbeda. Percobaan segmentasi dengan metode deteksi tepi menggunakan *Structured Edge Detector (SED)* (Yang, 2018) dan *Otsu's Thresholding* ditambah *Canny Edge Detector* (Zotin, 2019) berhasil mendeteksi batas area paru-paru dari citra X-Ray dada. Penelitian lain menggunakan pendekatan *Deep CNN* arsitektur AlexNet juga berhasil melakukan segmentasi paru-paru dari citra X-Ray dada (Souza, 2019). Ketiga penelitian tersebut sama-sama memiliki kesulitan di dalam mendeteksi tepi dan batas area paru-paru pada citra X-Ray yang memiliki gambaran paru-paru tidak normal, paru-paru tersebut tertutupi siluet putih atau memiliki bentuk berbeda karena sebab penyakit. Dengan kegagalan tersebut mengakibatkan nilai Intersection over Union (IoU) dari ketiganya tidak ada yang lebih dari 95%.

Pada penelitian ini segmentasi dilakukan dengan menggunakan arsitektur U-Net yang mana pernah digunakan dalam segmentasi paru-paru dari citra CT-Scan dada pasien Covid-19 (Asipong et al., 2021). Pada penelitian tersebut U-Net dapat dimodifikasi dengan mengurangi jumlah lapisan konvolusinya, pengurangan lapisan konvolusi dapat mempercepat waktu segmentasi dari model yang disusun. Improvisasi terhadap arsitektur U-Net juga dilakukan dengan mengkombinasikan modul atensi (Kim & Lee, 2021). Penelitian tersebut mengusulkan modul X- dan Y-Attention untuk meningkatkan performa dari segmentasi paru-paru pada X-Ray dada dengan memperjelas fitur. Modul atensi tersebut dikombinasikan dengan arsitektur U-Net sebagai arsitektur CNN yang cukup banyak digunakan dalam tugas segmentasi citra biomedis. Improvisasi U-Net dapat juga dilakukan dengan optimasi terhadap Hyperparameter yang digunakan. Dengan menggunakan optimasi bayesian, model performa dari model U-Net dapat ditingkatkan dalam melakukan tugas segmentasi, selain itu penambahan *Batch Normalization* juga meningkatkan kecepatan model dalam mencapai konvergensi saat pelatihan (Nishio et al., 2021).

Dengan mengacu pada beberapa variabel pada penelitian sebelumnya maka penelitian ini menggunakan dataset MC yang memiliki variasi derajat kerusakan paru-paru karena penyakit tuberkulosis dan menggunakan metode *Deep Learning* CNN dengan arsitektur U-Net yang populer dalam segmentasi citra biomedis dan arsitektur yang dapat dimodifikasi. Untuk improvisasi dari arsitektur U-Net maka ditambahkan lapisan Dropout karena Dropout dapat meningkatkan performa pada model segmentasi dengan dataset yang sedikit (Spilsbury & Camps, 2019).



Gambar 3. 1. Jenis Segmentasi dan Optimasinya

3.2. Metode Pengumpulan Data

Dataset citra *X-Ray* dada merupakan data pasien yang pada prakteknya didokumentasikan oleh institusi kesehatan seperti Rumah Sakit, foto rontgen diambil melalui alat radiologi yang tidak setiap orang dapat mengaksesnya. Data yang akan dipergunakan dalam penelitian ini merupakan dataset sekunder yang diambil dari dataset publik yang telah disediakan oleh peneliti terdahulu (Jaeger et al. 2014). Dataset yang telah dikumpulkan dari Montgomery County telah

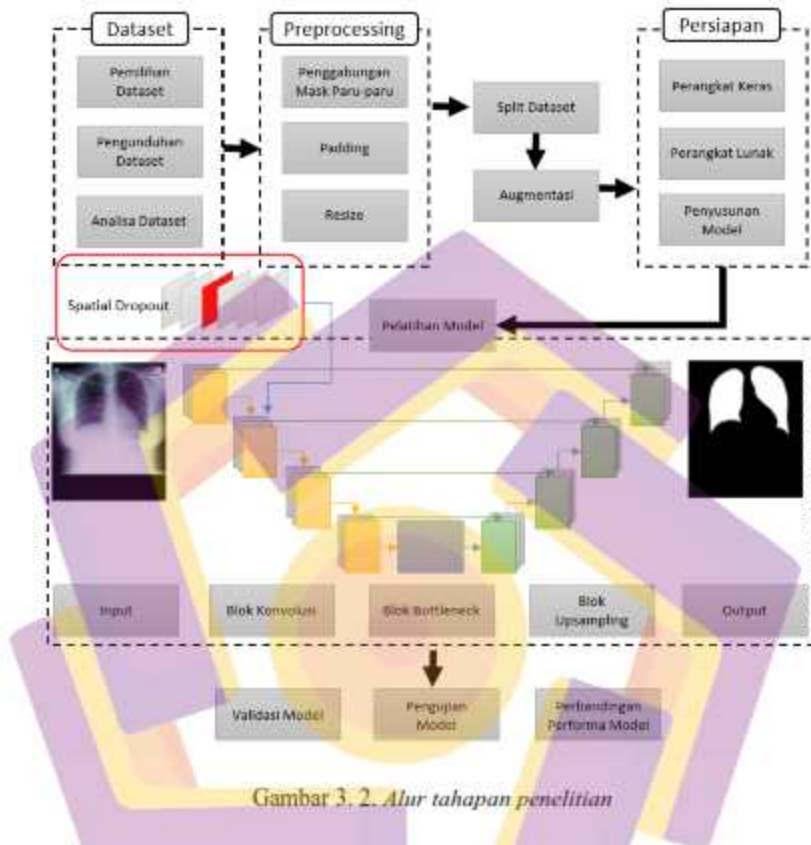
disediakan untuk praktek segmentasi sehingga peneliti tersebut telah menyediakan citra *X-Ray* dada beserta masking paru-parunya.

3.3. Metode Analisis Data

Data hasil percobaan pada penelitian ini akan diukur menggunakan tingkat akurasi, loss dan IoU atau Dice Coefficient. Hasil dari perhitungan disajikan berupa angka-angka sehingga metode analisis data yang akan dilakukan menggunakan metode kuantitatif. Akurasi diukur dari jumlah piksel yang diklasifikasikan dengan benar sebagai paru-paru ditambah dengan piksel yang diklasifikasikan dengan benar sebagai bukan paru-paru kemudian dibagi dengan jumlah dari piksel yang diklasifikasikan dengan benar sebagai paru-paru ditambah piksel yang diklasifikasikan dengan benar sebagai bukan paru-paru ditambah piksel yang salah diklasifikasikan sebagai paru-paru ditambah piksel yang salah diklasifikasikan sebagai bukan paru-paru dengan hasil akhir berupa berapa persen tingkat akurasi.

3.4. Alur Penelitian

Terdapat beberapa tahap yang akan dilakukan dalam penelitian ini. Penelitian akan dimulai dengan melakukan *preprocessing* citra *X-Ray* dada yang memiliki ukuran resolusi 4020 x 4892 piksel diturunkan menjadi 512 x 512 piksel.



3.4.1. Dataset

Dataset *X-Ray* dada yang pernah digunakan di dalam penelitian-penelitian sebelumnya terdapat beberapa macam diantaranya dataset JSRT, CRASS, MC dan SH. Dataset JSRT dan CRASS digunakan pada penelitian segmentasi paru-paru menggunakan metode SED (Yang, 2018). Dataset tersebut merupakan dataset yang diterbitkan pada tahun 2000 dan disiapkan untuk penelitian deteksi tumor paru-paru. Untuk dataset MC dan SH

diterbitkan untuk umum pada tahun 2014 dengan tujuan penelitian yang berbeda, dataset MC disiapkan secara khusus untuk penelitian segmentasi paru-paru, oleh karena itu di dalam dataset MC terdapat anotasi mask paru-paru yang dibuat dengan supervisi oleh radiologis (Jaeger et al. 2014). Selain dataset MC, Jaeger juga menerbitkan dataset SH yang berisikan kumpulan *X-Ray* dada tanpa anotasi masking paru-paru, dataset SH dipersiapkan untuk penelitian klasifikasi penyakit paru-paru.

Data citra *X-Ray* dada yang disediakan oleh (Jaeger et al. 2014) berjumlah 138 citra *X-Ray* dan 276 citra anotasi atau mask paru-paru. Dataset citra tersebut telah tersedia pada <https://md.ai> dan <https://www.kaggle.com/datasets/nikhilpandey360/chest-xray-masks-and-labels> yang dapat diunduh dengan cara melakukan registrasi terlebih dahulu. Resolusi dari citra *X-Ray* pada dataset tersebut 4020 x 4892 piksel dan format yang disediakan berupa format file DICOM namun tersedia juga dalam format PNG.

3.4.1.1. Analisa Dasar Dataset

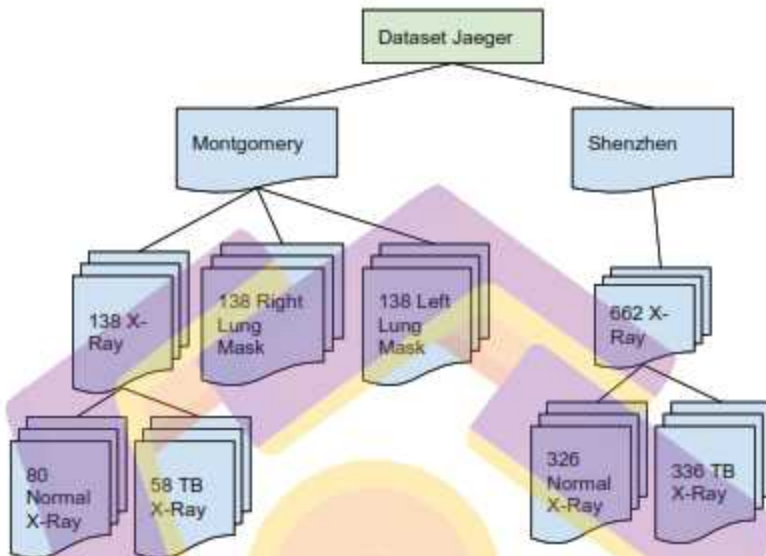
Jaeger et al. (2014) telah mempublikasikan 2 buah dataset *X-Ray* dada yang dikumpulkan dari 2 lokasi berbeda. Dataset pertama dari hasil kolaborasi dengan Department of Health and Human Services, Montgomery County, Maryland, USA. Dataset tersebut berisikan 138 *X-Ray* dada frontal / dari sisi depan yang dihasilkan dari program skrining tuberkulosis Montgomery County, yang mana 80 gambar adalah kasus normal dan 58 gambar kasus tuberkulosis. Citra *X-Ray* ditangkap

menggunakan mesin CR (*Computed Radiography*) dan disediakan dalam format (.PNG) sebagai gambar abu-abu 12-bit.

Untuk dataset kedua dikumpulkan dengan kolaborasi bersama Shenzhen No.3 People's Hospital, Guangdong Medical College, Shenzhen, China. *X-Ray* dada tersebut berasal dari pasien poliklinik rawat jalan yang dihasilkan dari aktivitas rutin sehari-hari selama 1 bulan menggunakan sistem diagnostic digital Philips DR. Berjumlah total 662 *X-Ray* dada dari arah depan dengan 326 kasus normal dan 336 kasus tuberculosis termasuk kasus tuberculosis pada anak. Gambar *X-Ray* tersedia dalam format (.PNG) dengan ukuran resolusi bervariasi namun kurang lebih 3K x 3K piksel.

Dari kedua dataset tersebut yang disediakan Ground Truth segmentasi paru-paru adalah dataset Montgomery dimana dataset tersebut disediakan secara publik untuk penelitian-penelitian serupa. Untuk dataset Shenzhen tidak disediakan Ground Truth segmentasi paru-paru karena Dataset tersebut disediakan untuk penelitian klasifikasi. Pembuatan segmen atau masking area paru-paru dilakukan dengan supervisi dari spesialis radiologi, mengikuti tanda-tanda secara anatomis seperti batas dari jantung, perikardium dan pembuluh aorta. Hasil dari masking paru-paru tersebut disimpan ke dalam file masking paru-paru kanan dan file masking paru-paru kiri.

3.4.1.2. Struktur Dataset





















Gambar 3. 3. Struktur Dataset

Dataset yang diperuntukkan secara khusus untuk melatih model segmentasi dimasukkan ke dalam kelompok folder Montgomery County (MC) sedangkan dataset yang diperuntukkan secara khusus untuk melatih model klasifikasi dimasukkan ke dalam kelompok folder Shenzen Hospital (SC) (Jaeger, 2014). Untuk dataset yang akan digunakan di dalam penelitian ini adalah dataset MC.


Di dalam gambar 3.3 diperlihatkan bahwa terdapat folder berisikan 138 buah gambar *X-Ray*, 138 buah gambar mask paru-paru kanan dan 138 buah gambar mask paru-paru kiri. Dari 138 buah gambar *X-Ray* dada tersebut terdapat 80 diantaranya merupakan gambaran paru-paru normal dan 58 gambar merupakan gambaran paru-paru dengan tuberkulosis.

3.4.1.3. Tampilan Dataset

Tabel 3. 1. Tampilan Dataset

No	Citra X-Ray	Right Lung Mask	Left Lung Mask
1)			
2)			
3)			
4)			
5)			
<i>Skip untuk nomor (6-133)</i>			
134)			

Tabel 3. 1. (Lanjutan)



Pada tabel dataset dapat terlihat bahwa setiap citra *X-Ray* dada memiliki dua buah area paru-paru yaitu paru-paru kanan dan paru-paru kiri. Anotasi ground truth bawaan dataset tersebut terdiri dari masking paru-paru kanan dan masking paru-paru kiri dengan file yang terpisah. Masking paru-paru kanan dan kiri digabungkan dan ditampilkan ke dalam tabel kolom ketiga. Pada kolom keempat ditampilkan hasil dari segmentasi paru-paru menggunakan masking ground truth bawaan dari dataset tersebut. Hasil segmentasi dari masking yang baik akan menghasilkan batas paru-paru yang tegas dan bentuk paru-paru yang rasional.

3.4.2. Pra pemrosesan (*pre processing*)

Arsitektur U-Net yang dibangun akan menggunakan input citra berukuran 512 x 512 piksel. Input citra harus berupa persegi sehingga ukuran citra *X-Ray* dada dari dataset perlu dilakukan resize terlebih dahulu dari ukuran 4020 x 4892 atau 4892 x 4020 piksel menjadi 512 x 512 piksel. Agar gambaran dari paru-paru tetap proporsional maka dilakukan cropping dan padding di luar area *X-Ray*. Setelah gambar atau citra berukuran 512 x 512 piksel selanjutnya dilakukan normalisasi dengan membagi nilai piksel dengan 255. Contoh dari gambar *X-Ray* dan anotasinya dapat dilihat pada gambar 3.4.



Gambar 3. 4. Contoh gambar *X-Ray* dada dan anotasi paru-parunya (Ground Truth) dengan proporsi resolusi asli.

3.4.3. Pembagian Dataset (*Splitting*)

Pemisahan dataset (*data splitting*) secara umum menggunakan rasio 80:20 atau 70:30 dimana angka pertama merupakan persentase dari seluruh data yang akan digunakan untuk data latih (*training*). Model yang dibangun harus belajar dan berlatih dari *training set* yang telah ditentukan. Pemisahan data ini juga bermanfaat untuk menghindari *overfitting* pada model yang dilatih dimana *overfitting* akan menyebabkan model memiliki performa

baik dalam data latihnya namun performanya buruk untuk menyesuaikan dengan data-data tambahan atau data-data baru. Dari seluruh dataset yang tersedia pada penelitian ini akan dibagi menjadi 80-85% dataset untuk pelatihan dan sisa datasetnya untuk pengujian.

3.4.4. Augmentasi

Dari sejumlah dataset yang tergolong ke dalam data latih dilakukan augmentasi dengan tujuan untuk memperbanyak data latih. Augmentasi dilakukan dengan cara melakukan rotasi dengan rentang rotasi dari 0 hingga 90 derajat, kemudian dengan melakukan pergeseran seluruh piksel secara horizontal dan vertikal dari rentang 0 hingga 30 persen, selain itu juga melakukan perbesaran (zoom) dan flip secara horizontal dan vertikal.

3.4.5. Optimasi *Learning-rate*

Learning rate merupakan sebuah skalar positif yang menentukan panjang langkah selama SGD. Pada banyak kasus, *learning rate* harus disetel secara manual selama pelatihan model, dan penyesuaian tersebut seringkali diperlukan untuk meningkatkan akurasi. Pilihan alternatif selain *learning rate* tetap (fixed) adalah *learning rate* yang bervariasi selama proses pelatihan berlangsung (Yu et al. 2020).

Learning rate scheduler digunakan dalam upaya menyesuaikan *learning rate* selama pelatihan dengan menyesuaikan *learning rate* sesuai dengan jadwal yang telah ditentukan sebelumnya. *Learning rate scheduler*

yang umum seperti step-decay dan exponential-decay. Berikut rumus dari exponential-decay:

$$lr = lr_0 \cdot \text{floor}^{\frac{\text{epoch}}{\text{epochsdrop}}}$$

3.4.6. Pelatihan (*Training*) Model Segmentasi U-Net

Model yang akan dilatih dalam proses ini adalah menggunakan arsitektur U-Net. Pada dasarnya arsitektur U-Net dikembangkan berdasarkan jaringan konvolusi dimana terdapat lapisan-lapisan konvolusi pada alur U-Net itu sendiri. Dibandingkan dengan arsitektur-arsitektur CNN lainnya, U-Net dirancang sejak awal pengembangannya khusus untuk segmentasi pada citra biomedis. Pelatihan model akan dilakukan dengan 10 kali pengulangan dan 100 langkah pada setiap pengulangannya. Pada akhir pengulangan dilakukan pengecekan loss function menggunakan binary cross entropy loss, apabila loss pada validasinya meningkat maka dilakukan update pada model. Berikut tahapan di dalam model yang akan dilatih:

3.4.6.1. Input

Untuk memulai proses pada pelatihan model dilakukan pembacaan terhadap citra *X-Ray* beserta (ground truth mask) dari dataset yang telah diunduh. Setiap citra yang telah dilakukan pra pemrosesan sebelumnya dengan ukuran 512 x 512 piksel mulai dibaca menggunakan proses konvolusi citra.

Untuk dapat melakukan proses konvolusi citra input diperlukan sebuah kernel. Pada model tersebut digunakan kernel konvolusi dengan ukuran 3 x 3.




512 x 512 piksel

Gambar 3. 5. Gambar yang digunakan sebagai Input

3.4.6.2. Konvolusi 3x3

Kernel 3 x 3 dijalankan menyusuri seluruh bagian citra, agar ukuran citra tidak berkurang maka diberikan padding pada proses konvolusi. Sesuai dengan arsitektur aslinya U-Net menggunakan *feature channels* 64, sehingga dari proses konvolusi menghasilkan 64 *feature maps*.


Pada setiap blok proses konvolusi dilakukan berulang dua kali. Hasil dari proses konvolusi selanjutnya akan dijadikan inputan proses downsampling menggunakan teknik pooling. Selain itu hasil dari konvolusi akan digabungkan pada proses *skip connection* menuju blok dekonvolusi.



Gambar 3. 6. Ilustrasi Konvolusi menghasilkan Lapisan Peta Fitur

3.4.6.3. Max-Pooling

Pada tahapan ini akan dilakukan max-pooling menggunakan kernel 2×2 pada citra hasil konvolusi dari blok sebelumnya. Dengan penerapan max-pooling ini maka ukuran dari citra setelahnya menjadi setengah dari ukuran citra sebelumnya.




Gambar 3. 7. Max-pooling menghasilkan ukuran $\frac{1}{2}$ dari sebelumnya

3.4.6.4. Dekonvolusi atau *Upsampling*

Pada tahapan ini kita akan menggunakan metode upsampling atau transposed convolution pada citra dimulai setelah tahapan bottleneck. tahapan upsampling merupakan tahapan pada bagian kanan, dimana setiap blok dilakukan dua kali transposed convolution atau upsampling dan dilakukan pengurangan feature channel setengah dari setiap tahapan sebelumnya.

3.4.6.5. Dropout Layer

Sebagai bentuk upaya dalam meningkatkan kemampuan pelatihan dari model akan diusulkan untuk menambahkan regularisasi dropout (Dropout Regularization). Dropout merupakan tehnik regularisasi yang digunakan untuk mencegah terjadinya overfitting pada model. Dropout dilakukan secara acak pada neuron-neuron tertentu dan bekerja dengan secara acak memblokir sebagian kecil neuron dalam lapisan selama pelatihan. Kemudian, selama prediksi (setelah pelatihan), dropout tidak memblokir neuron apa pun. Ketika dropout memblokir atau mematikan neuron maka koneksi datang dan keluarnya juga ikut dimatikan, hal ini dapat mencegah bagian tersebut melakukan adaptasi terlalu banyak.



Gambar 3. 8. Ilustrasi Dropout

Penambahan dropout dengan *Spatial Dropout* ke dalam model dilakukan sebagai kontribusi pada penelitian ini dengan harapan penambahan metode tersebut dapat meningkatkan performa dari model saat pelatihan. Penerapan algoritma Dropout ke dalam model segmentasi citra merupakan mekanisme yang efektif untuk meningkatkan performa segmentasinya (Spilsbury & Camps, 2019). Penambahan dropout dilakukan pada setiap blok konvolusi pada arsitektur U-Net seperti terlihat pada gambar 3.2. Dropout spasial digunakan untuk mengurangi sebagian lapisan peta fitur yang dihasilkan oleh proses konvolusi.

3.4.6.6. Pengujian dan Evaluasi

Untuk melakukan validasi atau pengujian dari model yang dilatih digunakan fungsi loss menggunakan binary cross-entropy loss. Fungsi


ini digunakan untuk mengetahui seberapa bagus model yang dilatih dalam mengetahui prediksi data latih.

Sebagai prosedur untuk melakukan penilaian terhadap performa dari model yang dilatih akan dilakukan pengujian akurasi piksel. Untuk dapat melakukan perhitungan akurasi ini kita hitung nilai True Positive, True Negative, False Positive dan False Negative.

$$\text{Akurasi Piksel} = \frac{TP + TN}{TP + TN + FP + FN}$$

Selain menggunakan Akurasi Piksel juga digunakan metode perhitungan IoU (*Intersection over Union*). Metode ini dilakukan dengan mengukur area perpotongan dan penyatuan antara anotasi asli dan prediksi. Untuk dapat menghitung IoU juga diperlukan adanya True Positive, False Positive dan False Negative.

$$IoU = \frac{\text{Intersection (Irisan)}}{\text{Union (Gabungan)}} = \frac{TP}{TP + FP + FN}$$



Gambar 3. 9. Ilustrasi Perhitungan Nilai Tumpang Tindih (*IoU*)

BAB IV

HASIL PENELITIAN DAN PEMBAHASAN

4.1. Pengunduhan Dataset



















Kumpulan data citra hasil foto *X-Ray* dada diunduh dari situs kaggle(<https://www.kaggle.com/datasets/nikhilpandey360/chest-xray-masks-and-labels>). Dataset hasil unduhan dengan format file zip diekstrak terlebih dahulu, hasil dari ekstraksi zip berisikan folder montgomery. Terdapat tiga buah folder di dalam root folder montgomery yaitu *ClinicalReadings*, *CXR_png* dan *ManualMask*. Untuk folder *ClinicalReadings* tidak digunakan karena berisikan data label untuk klasifikasi dengan parameter jenis kelamin, usia dan diagnosa tuberkulosis atau bukan tuberkulosis. Gambar *X-Ray* dada berada di dalam folder *CXR_png* dengan jumlah 138 file format PNG berukuran rata-rata 4 megabyte, kedalaman 8 bit, dimensi 4020 x 4892 piksel atau 4892 x 4020 piksel.

Dimensi dari gambar *X-Ray* berbeda dikarenakan perbedaan posisi film atau kanvas yang diletakkan di dalam alat *X-Ray*, hal tersebut tergantung dari petugas yang melakukan pemeriksaan menyesuaikan dengan kebutuhan atau kondisi pasien seperti ukuran lebar tubuh pasien. Untuk ukuran tubuh besar atau lebar dipilih posisi lansekap daripada posisi protrait. Untuk anotasi atau masking paru-paru dapat ditemukan di dalam folder *ManualMask*, terdapat dua buah folder di dalamnya yang merupakan kumpulan masking paru-paru kiri (folder *leftMask*) dan kumpulan masking paru-paru kanan (folder *rightMask*). Masing-masing folder masking













tersebut berisi 138 file sehingga setiap gambar *X-Ray* paru-paru memiliki satu pasang file masking paru-paru kiri dan kanan.

4.2. Anallsa Dataset

Tabel 4. 1. Tabel Rincian Dataset

No	Citra <i>X-Ray</i>	Bacaan Klinis	Mask Kanan	Mask Kiri	Resolusi
1)		Patient's Sex: F Patient's Age: 027Y normal			4892x4020 px
2)		Patient's Sex: F Patient's Age: 040Y normal			4892x4020 px
3)		Patient's Sex: F Patient's Age: 021Y normal			4020x4892 px
4)		Patient's Sex: F Patient's Age: 011Y normal			4020x4892 px
5)		Patient's Sex: M Patient's Age: 033Y normal			4020x4892 px
134)		Patient's Sex: F Patient's Age: 014Y calcified granuloma LUL behind 4th rib anterior			4020x4892 px

Tabel 4. 1. (Lanjutan)

135)		Patient's Sex: M Patient's Age: 042Y inactive scars RUL			4020x4892 px
136)		Patient's Sex: M Patient's Age: 052Y Rt apical scarring, LUL scars and some infiltrates as well; findings consistent with TB; ?active			4020x4892 px
137)		Patient's Sex: F Patient's Age: 030Y left pleural effusion; best seen on lateral view; with some scar and soft infiltrates in the LUL on the PA and lordotic views; active TB on pleura and lung likely			4020x4892 px
138)		Patient's Sex: F Patient's Age: 063Y large infiltrate RUL with cavitation plus infiltrate in RML consistent with active cavity TB			4020x4892 px

Seluruh dataset telah dianalisa dengan memastikan ukuran resolusi masing-masing citra *X-Ray* dan masking paru-parunya. Setiap citra *X-Ray* memiliki dua buah masking paru-paru yaitu paru-paru kanan dan paru-paru kiri. Masing-masing citra paru memiliki bacaan klinis yang merupakan hasil bacaan oleh spesialis

radiologi. Secara umum bacaan tersebut terdiri dari paru-paru normal dan paru-paru dengan tuberkulosis.

Pada tabel 4.1 telah ditampilkan dataset dengan kolom berisikan gambar *X-Ray*, bacaan klinis, masking paru-paru kanan, masking paru-paru kiri dan ukuran resolusi. Dataset yang ditampilkan diambil dari 5 dataset paru-paru normal dan 5 buah dataset paru-paru tuberkulosis.

4.3. Pra Pemrosesan Dataset

Seluruh data yang telah dianalisa kemudian dilakukan pra pemrosesan agar setiap gambar dapat dijadikan masukan pada pelatihan model. Terdapat beberapa tahapan pada pra pemrosesan sebagai berikut:

4.3.1. Penggabungan Anotasi Masking

Anotasi masking paru-paru dari dataset terdiri dari masking paru-paru kanan dan paru-paru kiri di dalam file yang terpisah. Masking dari paru-paru kanan dan kiri yang terpisah dapat dipergunakan untuk melakukan melatih model segmentasi secara terpisah, namun pada penelitian ini model dilatih untuk melakukan prediksi terhadap paru-paru secara keseluruhan.

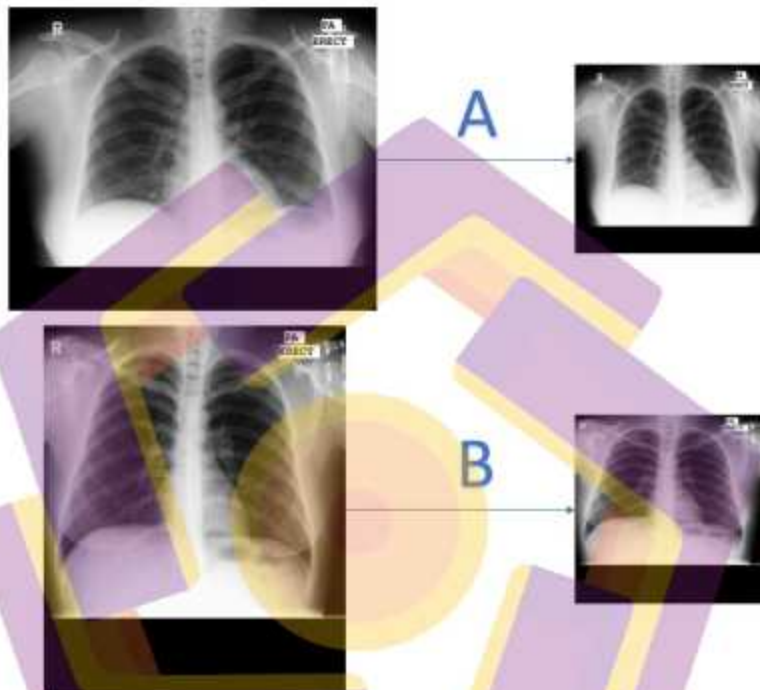
Penggabungan anotasi masking paru-paru kanan dan kiri dilakukan dengan mengiris citra separuh bagian dan membuang bagian yang berwarna hitam, selanjutnya citra yang tersisa digabungkan antara irisan paru-paru kanan dengan paru-paru kiri. Hasil dari penggabungan harus berdimensi sama dengan citra *X-Ray* yang bersangkutan. Hasil dari penggabungan citra anotasi masking paru-paru dapat dilihat pada gambar di bawah.



4.3.2. Resize

Di dalam dataset yang telah diunduh terdapat dua tipe orientasi citra *X-Ray*, yang pertama dengan orientasi lansekap dan yang kedua dengan orientasi protrait. Dari ukuran gambar asli *X-Ray* dan gambar asli masking paru-paru dimensi 4020 x 4892 piksel dan sebaliknya diturunkan menjadi ukuran persegi 256 x 256 piksel

gambar. Pengurangan ukuran dimensi gambar bertujuan agar dapat dimasukkan ke dalam input dari model arsitektur U-Net.




Gambar 4. 2 Resize terhadap citra *X-Ray*

Untuk melakukan resize gambar setiap dataset digunakan fungsi resize pada library OpenCV di Python. Kode untuk melakukan resize adalah `cv2.resize()`. Pada tahapan resize ini gambar menjadi berukuran persegi dan berdampak pada rasio paru-paru yang berubah. Dari gambar asli dengan orientasi lansekap maka akan didapatkan paru-paru yang lebih menyempit ditunjukkan pada huruf A gambar 4.1,

sedangkan untuk hasil resize dari citra berorientasi portrait dihasilkan citra dengan paru-paru yang melebar seperti pada huruf B.

4.3.3. Padding

Setelah dilakukan resize pada citra dari ukuran 4020 x 4892 piksel menjadi 256 x 256 piksel selanjutnya dilakukan padding pada citra agar proporsi gambar tetap sesuai aslinya. Hal tersebut bertujuan agar gambar hasil resize tidak menampilkan paru-paru yang lebih lebar atau lebih tinggi daripada aslinya.



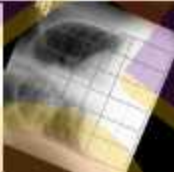



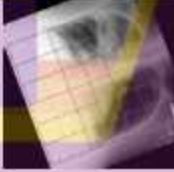
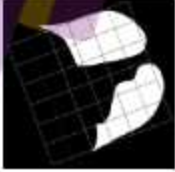
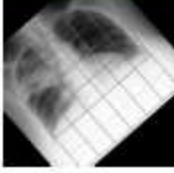

Gambar 4. 3 Penambahan Padding

Pada gambar 4.2 dapat dilihat penambahan padding pada citra *X-Ray* dan citra masking paru-paru. Padding dilakukan agar gambar memiliki bentuk persegi. Dapat dilihat pada gambar terdapat lingkaran kuning yang menunjukkan area tambahan berwarna hitam pada citra *X-Ray*, panjang dari sisi A sama dengan panjang sisi B. Padding pada citra masking paru-paru dilakukan setelah masking paru-paru kanan digabungkan dengan masking paru-paru kiri.

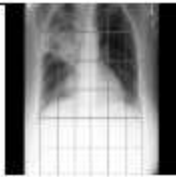
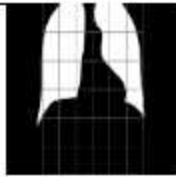
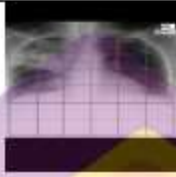

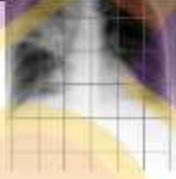





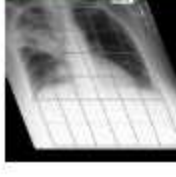

4.3.4. Augmentasi

Dari dataset yang ada hanya berjumlah 138 citra dan 138 masking paru-paru dilakukan augmentasi pada dataset yang dijadikan data latih. Untuk melakukan augmentasi digunakan library tensorflow dengan fungsi ImageDataGenerator.

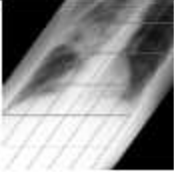







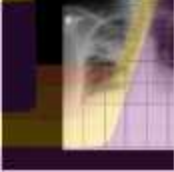


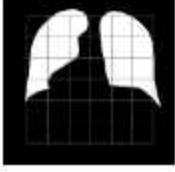
Tabel 4. 2 Hasil dari data augmentasi

No.	Metode	Citra <i>X-Ray</i>	Mask Paru-Paru
1.	Rotation Range = -90 - 90 derajat		
2.	Rotation Range = -90 - 90 derajat		
3.	Rotation Range = -90 - 90 derajat		
4.	Rotation Range = -90 - 90 derajat		


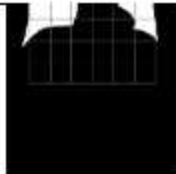
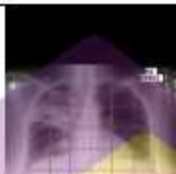




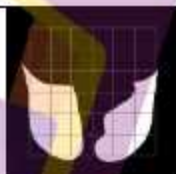
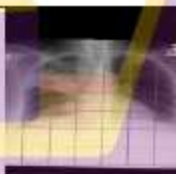



Tabel 4. 2. (Lanjutan)

5.	Zoom hingga 40%		
6.	Zoom hingga 40%		
7.	Zoom hingga 40%		
8.	Zoom hingga 40%		
9.	Shear rentang 50%		
10.	Shear rentang 50%		

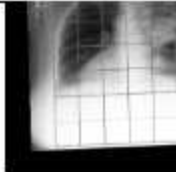
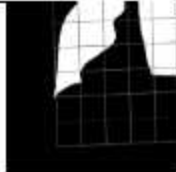


Tabel 4. 2. (Lanjutan)

11.	Shear rentang 50%		
12.	Shear rentang 50%		
13.	Height Shift range 90%		
14.	Height Shift range 90%		
15.	Height Shift range 90%		
16.	Horizontal Flip		

Tabel 4. 2. (Lanjutan)

17.	Width shift range 90%		
18.	Width shift range 90%		
19.	Width shift range 90%		
20.	Vertical Flip		
21.	Kombinasi		
22.	Kombinasi		

Tabel 4. 2. (Lanjutan)

23.	Kombinasi		
24.	Kombinasi		

4.4. Melakukan Training Model Segmentasi U-Net

4.4.1. Setup perangkat keras

Pelatihan model segmentasi U-Net dilakukan menggunakan perangkat keras yang memiliki kemampuan untuk melakukan deep learning. Kemampuan *Deep Learning* dilihat dari kemampuan kartu grafis yang digunakan.

Untuk persiapan perangkat keras dilakukan dengan menentukan spesifikasi komputer yang dipergunakan. Pada percobaan yang dilakukan menggunakan komputer desktop dengan spesifikasi processor AMD Vishera fx-6300 3.5GHz, RAM DDR3 12800 16 Gigabyte, graphic card NVidia Geforce RTX2060 ultra. Kemampuan dari kartu grafis yang digunakan untuk melakukan deep learning dilihat dari jumlah *Cuda Core* yang dimiliki, untuk Nvidia Geforce RTX2060 ultra memiliki inti *Cuda* sejumlah 1920 inti. Kartu grafis yang dikenalkan pada tahun 2019 tersebut

merupakan generasi pertama dari seri RTX untuk kartu grafis Geforce dari Nvidia.

4.4.2. Setup perangkat lunak

Pembelajaran deep learning memanfaatkan library tensorflow yang diketik dalam bahasa pemrograman python. Library tensorflow dapat berjalan dengan metode gpu atau non gpu, pada metode non gpu digunakan processor sebagai perangkat keras utama untuk komputasi, penggunaan processor lebih mudah dalam persiapannya karena tidak memerlukan konfigurasi yang rumit, namun penggunaan processor sebagai perangkat komputasi utama tanpa gpu menyebabkan proses pembelajaran yang sangat lambat dibandingkan menggunakan komputasi GPU.

Untuk menerapkan tensorflow dengan komputasi GPU diperlukan beberapa perangkat lunak pendukung. Pada penelitian ini digunakan kombinasi perangkat lunak Windows 10 untuk sistem operasinya, python 3.7 sebagai bahasa pemrogramannya.

Dalam melakukan setup perangkat lunak diperlukan beberapa Langkah dalam mengaktifkan tensorflow. Tensorflow digunakan untuk mengaktifkan GPU sebagai perangkat dalam pembelajaran, apabila tensorflow tidak diaktifkan maka pembelajaran hanya akan menggunakan CPU sebagai perangkat latihnya.

4.4.3. Menyusun Kode Program

Setelah model disusun dengan kode bahasa python maka dilakukan *summary* model dengan isi sebagai berikut:

Tabel 4. 3. Summary Model U-Net

Model: "U-Net"

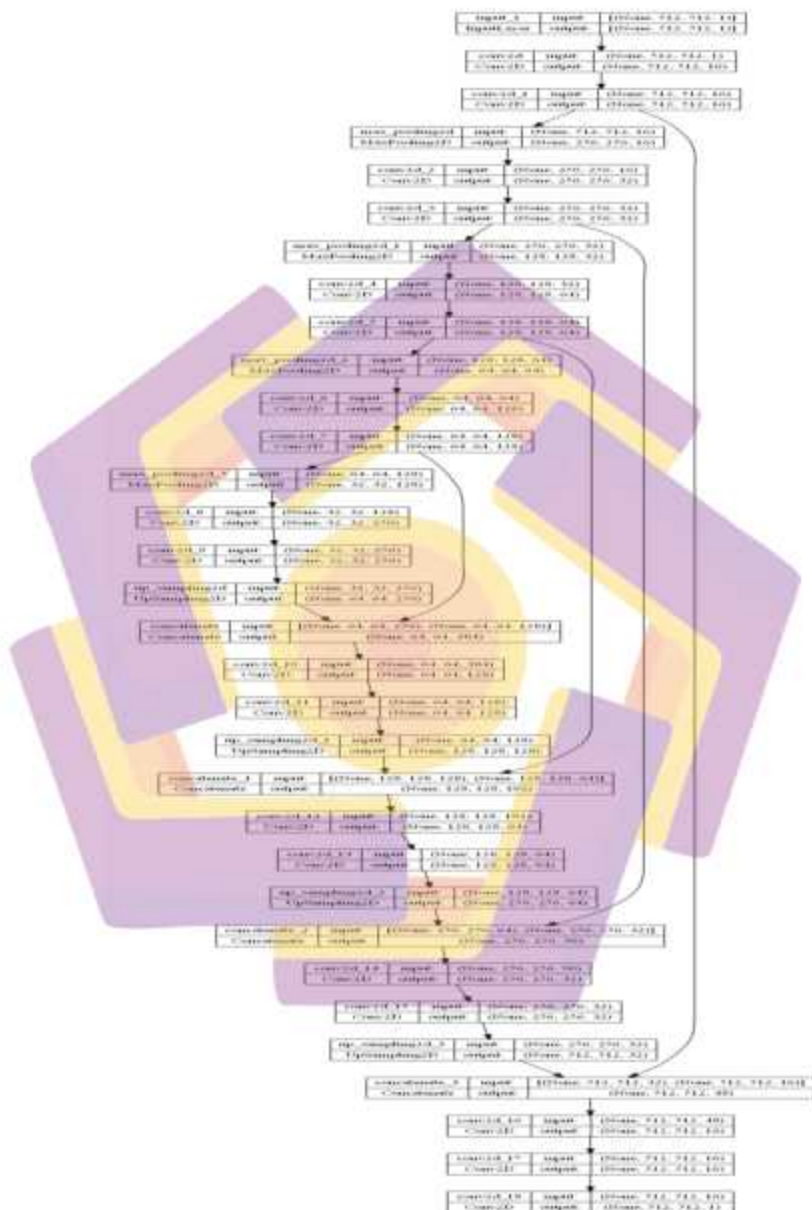
Layer (type)	Output shape	Param #	Connected to
input_1 (InputLayer)	(None, 512, 512, 3)	0	[]
conv2d (Conv2D)	(None, 512, 512, 16)	140	['input_1[0][0]']
conv2d_1 (Conv2D)	(None, 512, 512, 16)	2320	['conv2d[0][0]']
max_pooling2d (MaxPooling2D)	(None, 256, 256, 16)	0	['conv2d_1[0][0]']
conv2d_2 (Conv2D)	(None, 256, 256, 32)	4960	['max_pooling2d[0][0]']
conv2d_3 (Conv2D)	(None, 256, 256, 32)	9248	['conv2d_2[0][0]']
max_pooling2d_1 (MaxPooling2D)	(None, 128, 128, 32)	0	['conv2d_3[0][0]']
conv2d_4 (Conv2D)	(None, 128, 128, 64)	19496	['max_pooling2d_1[0][0]']
conv2d_5 (Conv2D)	(None, 128, 128, 64)	38928	['conv2d_4[0][0]']
max_pooling2d_2 (MaxPooling2D)	(None, 64, 64, 64)	0	['conv2d_5[0][0]']
conv2d_6 (Conv2D)	(None, 64, 64, 128)	73856	['max_pooling2d_2[0][0]']
conv2d_7 (Conv2D)	(None, 64, 64, 128)	147584	['conv2d_6[0][0]']
max_pooling2d_3 (MaxPooling2D)	(None, 32, 32, 128)	0	['conv2d_7[0][0]']
conv2d_8 (Conv2D)	(None, 32, 32, 256)	205168	['max_pooling2d_3[0][0]']
conv2d_9 (Conv2D)	(None, 32, 32, 256)	510280	['conv2d_8[0][0]']
up_sampling2d (UpSampling2D)	(None, 64, 64, 256)	0	['conv2d_9[0][0]']
concatenate (Concatenate)	(None, 64, 64, 384)	0	['up_sampling2d[0][0]', 'conv2d_7[0][0]']
conv2d_10 (Conv2D)	(None, 64, 64, 128)	42496	['concatenate[0][0]']
conv2d_11 (Conv2D)	(None, 64, 64, 128)	147584	['conv2d_10[0][0]']
up_sampling2d_1 (UpSampling2D)	(None, 128, 128, 128)	0	['conv2d_11[0][0]']
concatenate_1 (Concatenate)	(None, 128, 128, 192)	0	['up_sampling2d_1[0][0]', 'conv2d_9[0][0]']
conv2d_12 (Conv2D)	(None, 128, 128, 64)	11856	['concatenate_1[0][0]']
conv2d_13 (Conv2D)	(None, 128, 128, 64)	38928	['conv2d_12[0][0]']
up_sampling2d_2 (UpSampling2D)	(None, 256, 256, 64)	0	['conv2d_13[0][0]']
concatenate_2 (Concatenate)	(None, 256, 256, 96)	0	['up_sampling2d_2[0][0]', 'conv2d_11[0][0]']
conv2d_14 (Conv2D)	(None, 256, 256, 32)	27888	['concatenate_2[0][0]']
conv2d_15 (Conv2D)	(None, 256, 256, 32)	8248	['conv2d_14[0][0]']
up_sampling2d_3 (UpSampling2D)	(None, 512, 512, 32)	0	['conv2d_15[0][0]']
concatenate_3 (Concatenate)	(None, 512, 512, 48)	0	['up_sampling2d_3[0][0]',

Tabel 4. 3. (Lanjutan)

			conv2d_1(0)(0)'
conv2d_16 (Conv2D)	(None, 512, 512, 16)	8928	1*'concatenate_3(0)(0)*'
conv2d_17 (Conv2D)	(None, 512, 512, 16)	2820	1*'conv2d_16(0)(0)*'
conv2d_18 (Conv2D)	(None, 512, 512, 1)	17	1*'conv2d_17(0)(0)*'
<hr/>			
Total params: 1,962,337			
Trainable params: 1,962,337			
Non-trainable params: 0			

Selanjutnya setelah dilakukan fungsi *summary* terhadap model yang telah disusun tersebut ditampilkan ke dalam bagan sebagai berikut:





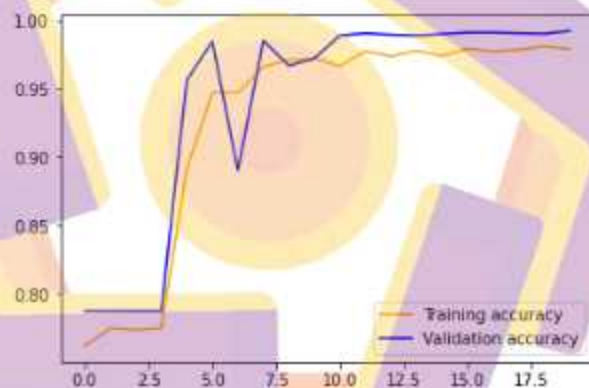
Gambar 4. 4. Diagram Model U-Net

4.5. Hasil Training dan Validasi Model Segmentasi U-Net

Setelah dilakukan pelatihan model segmentasi U-Net dengan beberapa skema didapatkan hasil sebagai berikut:

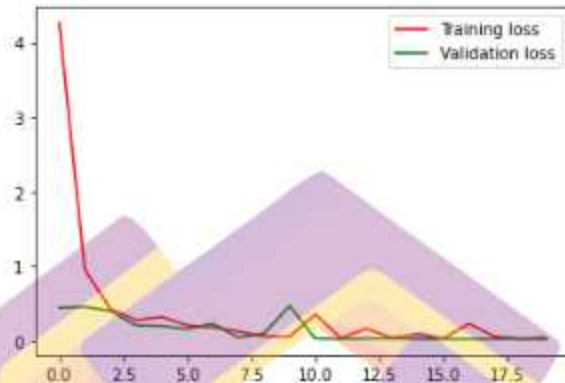
4.5.1. Percobaan I

Pada percobaan ke-I pelatihan model dilakukan dengan konfigurasi metode sederhana (*simple*) pada tahapan *upsampling*-nya, jumlah filter 16 dan aktivasi pada output menggunakan sigmoid. Penambahan *upsampling-simple* menggunakan fungsi `UpSampling2D` pada keras.



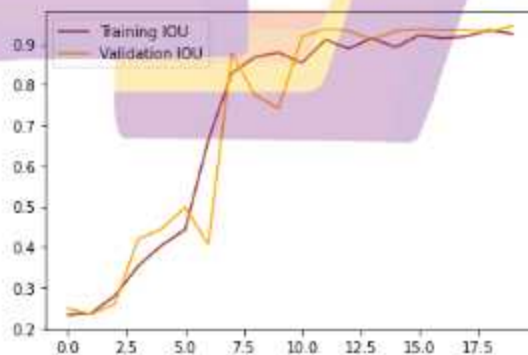
Gambar 4. 5. Grafik perubahan tingkat akurasi metode *Simple Upsampling*

Pada percobaan pertama dilakukan dengan jumlah epoch 20 kali dan didapatkan hasil akurasi 97,91%, IoU 92,46% dan nilai loss 0,0419. Setelah dilakukan validasi didapatkan nilai akurasi 99,23%. Nilai akurasi terlihat pada grafik naik cukup signifikan pada epoch ke-5 dari 77,46% menjadi 89,17% dan saat validasi naik dari 78,75% menjadi 95,63%.



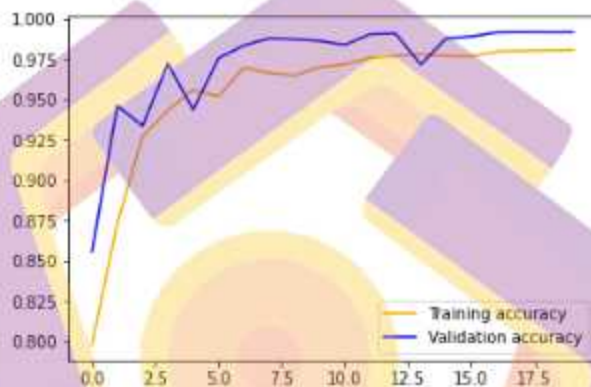
Gambar 4. 6 Grafik perubahan nilai loss metode *Simple Upsampling*

Percobaan pertama menunjukkan nilai loss saat validasi lebih rendah 0,023 daripada nilai loss saat pelatihan epoch ke-20. Nilai loss validasi menunjukkan angka 0,0189. Semakin kecil nilai loss maka semakin baik performa model tersebut. Perubahan signifikan dari nilai loss terjadi pada epoch ke-2 dari angka 4,2644 menjadi 0,9534.




Gambar 4. 7 Grafik perubahan nilai IoU pada metode *Simple Upsampling*

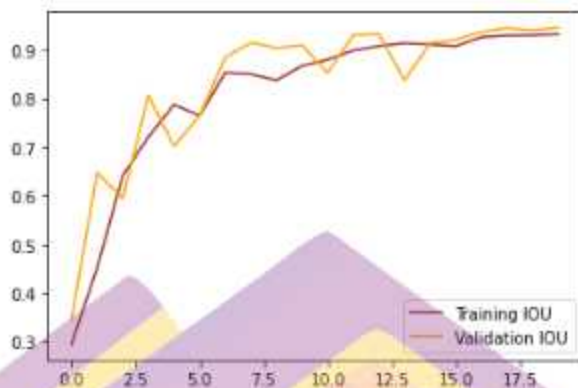
Pada percobaan ke-II pelatihan model dilakukan dengan konfigurasi metode *transposed convolution* pada tahapan *upsampling*-nya, jumlah filter 16 dan aktivasi pada output menggunakan sigmoid. Penambahan *upsampling transpose* menggunakan fungsi *Conv2DTranspose* pada keras.



Gambar 4. 8. Grafik tingkat akurasi pelatihan dengan metode dekonvolusi *Transposed Convolution*



Gambar 4. 9. Grafik nilai loss pada pelatihan metode dekonvolusi *Transposed Convolution*



Gambar 4. 10. Grafik perubahan nilai IoU pada pelatihan metode dekonvolusi *Transposed Convolution*.

Dari hasil yang didapatkan pada percobaan ke-I dan ke-II dapat dilihat bahwa tidak terdapat perbedaan yang signifikan antara metode dekonvolusi menggunakan teknik *upsampling simple* ataupun menggunakan *transpose convolution*. Perbandingan hasil antara kedua metode dapat dilihat pada tabel di bawah.

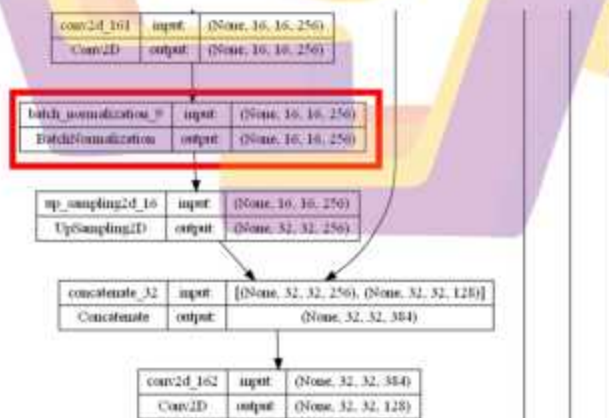
Tabel 4. 4. Perbandingan Nilai akhir antara metode dekonvolusi *Simple Upsampling* dan *Transposed Convolution*

Nilai Untuk	Simple Upsampling	Transpose Convolution
Time per step	212ms	212ms
Loss	0.0419	0.0256
Accuracy	0.9791	0.9807
IoU	0.9246	0.9332
Val loss	0.0189	0.0201
Val accuracy	0.9923	0.9917
Val IoU	0.9442	0.9464
epochs	20	20

Pada dasarnya metode upsampling yang digunakan pada arsitektur U-Net pada bagian kanan atau arah naik dilakukan menggunakan teknik transposed convolution namun terdapat metode lain untuk melakukan upsampling dengan menggunakan metode bilinear atau simple. Keuntungan menggunakan simple upsampling adalah tidak adanya parameter yang dibawa dan dapat diikuti dengan konvolusi 1×1 sehingga diharapkan dapat lebih ringan daripada transposed convolution. Namun dengan demikian transposed convolution dapat lebih detail dalam menangkap sebuah detail yang sangat kecil. Pada percobaan tersebut ternyata antara keduanya tidak terdapat perbedaan hasil yang signifikan.

4.5.2. Percobaan II


Untuk perbandingan selanjutnya dilakukan percobaan dengan menambahkan lapisan *batch normalization (BN)* pada model. Lapisan BN ditambahkan pada masing-masing lapisan, BN dilakukan setelah konvolusi selesai.



Gambar 4. 11. Posisi BN pada bagan model

Untuk menambahkan BN pada arsitektur model diperlukan fungsi BatchNormalization pada tensorflow/keras. Blok fungsi BN diposisikan setelah blok konvolusi sebagaimana dapat dilihat pada gambar gambar 4.11.

Berikut ditampilkan hasil dari proses pelatihan model segmentasi dengan penambahan BN di dalam arsitekturnya.



Gambar 4. 12. Grafik percobaan *training* dengan *Batch Normalization*

Dengan adanya penambahan BN pada arsitektur model segmentasi tersebut mengakibatkan kurva pembelajaran terlihat mulus, tidak tampak adanya fluktuasi grafik yang signifikan dibandingkan dengan sebelum ditambahkan BN. Selain itu setelah penambahan BN model dapat lebih cepat mencapai early stopping dengan perbandingan pada tabel di bawah ini.

Tabel 4. 5. Tabel perbandingan nilai akhir untuk BN dan tanpa BN

Nilai untuk	Tanpa BN	Dengan BN
Time per step	212ms	120ms
Loss	0.0419	0.0165
Accuracy	0.9791	0.9836
Iou	0.9246	0.9551
Val loss	0.0189	0.0176
Val accuracy	0.9923	0.9928
Val iou	0.9442	0.9549
epochs	20	14

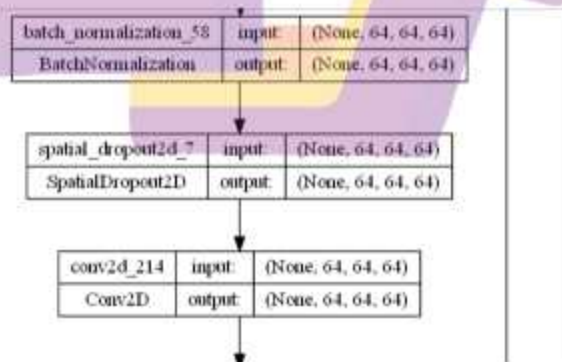
Pada percobaan ke-II ini ditambahkan algoritma BN untuk mencari apakah BN dapat meningkatkan kualitas dari pelatihan model yang disusun. Penambahan BN dapat meningkatkan kecepatan model dalam mencapai konvergensi saat

pelatihan (Nishio et al., 2021). Setelah dilakukan percobaan terbukti bahwa penambahan BN meningkatkan performa dari model tersebut. Pada tabel 4.5 ditampilkan hasil dari pelatihan dengan BN menunjukkan nilai Loss, Accuracy dan IoU yang lebih baik daripada model tanpa BN, selain itu dengan adanya BN model dapat mencapai konvergensi lebih cepat terlihat pada grafik dalam gambar 4.12.

4.5.3. Percobaan III


Untuk percobaan berikutnya dilakukan penambahan lapisan *dropout* (DO) pada arsitektur model segmentasi U-Net. Lapisan *dropout* ditambahkan pada setiap blok konvolusi pada bagian *downsampling*, diletakkan pada saat BN telah dilakukan. Untuk menambahkan lapisan DO digunakan fungsi *SpatialDropout2D* dari pustaka keras.

Dari kode yang ditambahkan tersebut akan menambahkan lapisan DO dengan jumlah *dropout* 10% dengan metode *spatial* pada blok konvolusi setelah dilakukan BN. Dapat dilihat pada bagan berikut ini untuk lapisan DO yang ditambahkan:



Gambar 4. 13. Bagan penambahan fungsi DO

Hasil dari pelatihan model dengan penambahan *dropout* 10% dapat dilihat pada gambar grafik di bawah ini. Dari gambar paling kiri adalah grafik perkembangan nilai akurasi, gambar kedua grafik perkembangan nilai IoU dan terakhir grafik perkembangan nilai fungsi loss.



Gambar 4. 14. Gambar grafik perkembangan nilai pelatihan dan validasi dengan DO10%

Dengan penambahan DO maka terlihat hasil tidak jauh berbeda dengan tanpa DO. Untuk model dengan penambahan DO 10% berdampak pada peningkatan performa yang lebih pelan daripada tanpa DO. Pada model dengan DO 10% peningkatan performa latih terakhir terjadi pada epoch ke-19 sedangkan tanpa DO terjadi pada epoch ke-14. Dengan penambahan DO yang dapat meningkatkan jumlah epoch yang dapat dicapai oleh model pada saat pelatihan, maka diperlukan percobaan untuk mencari berapa level DO yang baik untuk dapat diterapkan ke dalam model U-Net tersebut. Dengan demikian model diharapkan tidak terlalu cepat dalam mencapai posisi *plateau*.

Tabel 4. 6. Tabel Perbandingan *Batch Normalization* dan *Dropout*

	Tanpa BN	Dengan BN	Dengan BN + DO
Time per step	212ms	230ms	230ms
Loss	0.0419	0.0165	0.0167
Accuracy	0.9791	0.9836	0.9835

Tabel 4. 6. (Lanjutan)

IoU	0.9246	0.9551	0.9544
Val loss	0.0189	0.0176	0.0173
Val accuracy	0.9923	0.9928	0.9932
Val IoU	0.9442	0.9549	0.9568
epochs	20	14	19

Jika dilihat dari hasil performa yang didapatkan dengan adanya lapisan DO maka belum terlihat signifikan perubahannya, karena pada saat percobaan ke-III hanya dilakukan dengan epoch kurang dari 20. Namun dampak dari DO terlihat pada jumlah epoch yang didapatkan lebih panjang daripada tanpa DO, hal ini akan menambah kemampuan komputer dalam melatih model tersebut sehingga diharapkan penambahan DO dapat meningkatkan performa akhir dari model segmentasi.

4.5.4. Percobaan IV

Penambahan *Dropout Regularization* sebagai upaya dalam mengurangi risiko *overfitting* dari model yang dibangun. Untuk mencari berapa nilai prosentasi dari DO diperlukan percobaan dari beberapa nilai dalam rentang lebih dari 0% dan kurang dari 100% DO.

Untuk melihat performa model dengan penambahan DO dilakukan percobaan penambahan lapisan DO dengan bertahap mulai dari DO 10% hingga DO 90%. Hasil dari percobaan DO 10% hingga 90% dapat dilihat pada tabel sebagai berikut:


Tabel 4. 7. Tabel Nilai Performa rentang dropout 10% hingga 90%

Dropout (%)	Acc	Val Acc	IoU	Val IoU	Delta Acc	Delta IoU	Epoch
DO10	97,62	98,45	88,14	90,81	0,83	2,67	40

Tabel 4. 7. (Lanjutan)


DO20	97,67	98,57	88,52	90,89	0,91	2,37	55
DO30	97,45	98,38	87,00	89,19	0,93	2,19	53
DO40	97,26	98,21	85,84	88,27	0,95	2,43	70
DO50	94,96	93,73	71,75	68,40	-1,23	-3,36	31
DO60	93,49	94,39	63,60	57,87	0,90	-5,73	26
DO70	93,61	92,29	63,75	57,68	-1,32	-6,07	17
DO80	87,27	88,44	38,41	37,15	1,17	-1,26	10
DO90	80,22	78,59	25,14	26,70	-1,63	1,56	10

Pada tabel di atas ditampilkan nilai hasil pelatihan dengan skema percobaan penambahan DO dari rentang 10% hingga 90%. Hasil dari masing-masing DO menunjukkan perubahan yang dapat ditampilkan ke dalam grafik.



Gambar 4. 15. Grafik perkembangan nilai akurasi penambahan DO

Peningkatan jumlah DO pada model mempengaruhi hasil dari akurasi yang didapatkan. Dapat dilihat pada grafik akurasi mulai mengalami penurunan pada DO 50%, hal tersebut tampak juga pada akurasi saat validasi (garis berwarna jingga). Agar model tetap memiliki performa yang baik dalam akurasi pikselnya maka jangan menambahkan DO lebih dari 50%.



Gambar 4. 16. Grafik perkembangan nilai IoU penambahan DO


Sebagaimana pada hasil nilai akurasi yang mengalami penurunan pada penambahan DO tertentu, nilai dari IoU juga mengalami penurunan setelah penambahan DO 50%. Dapat dilihat pada grafik bahwa nilai dari IoU semakin tidak masuk akal pada penambahan lapisan DO, semakin banyak DO maka IoU semakin berkurang. Untuk menjaga nilai IoU dari model tersebut maka perlu membatasi DO tidak lebih dari 40%.

Untuk memastikan bahwa nilai dari akurasi dan nilai dari IoU model menunjukkan hasil yang valid maka dilakukan validasi menggunakan dataset untuk validasi. Perbedaan nilai dari validasi dengan nilai dari pelatihan akan menggambarkan apakah model tersebut mengalami overfitting atau underfitting. Perbedaan nilai disebut dengan nilai delta yang dapat dilihat pada grafik berikut ini.



Gambar 4. 17. Grafik perubahan nilai Delta

Penambahan prosentase dari DO juga mempengaruhi seberapa lama model tersebut dapat bertahan untuk melakukan pelatihan. Jumlah epoch yang dapat dicapai terlihat cukup tinggi pada DO 20% hingga DO 40%.



Gambar 4. 18. Grafik jumlah epoch masing-masing DO

Agar pelatihan model dapat mencapai puncak dari performanya diperlukan epoch yang tepat. Penambahan DO terlihat dapat mempengaruhi jumlah epoch yang

dapat dicapai oleh model pada saat pelatihan. Dari grafik epoch tersebut dapat dilihat bahwa model dapat mencapai epoch tertinggi dengan menambahkan DO 40%.

Dengan perbedaan hasil dari performa saat pelatihan dan validasi menggunakan metode penambahan lapisan DO maka perlu ditentukan konfigurasi DO yang paling baik untuk melatih model U-Net tersebut. Dari nilai akurasi dapat diambil DO 10% - 40%, dari nilai IoU dapat diambil DO 10% - 40%, untuk delta dapat diambil DO 30% - 40% dan untuk jumlah epoch dapat mengambil DO 20% - 40%. Untuk pelatihan model yang diusulkan akan mengambil nilai DO 30%.

4.6. Hasil Pengujian dan Perbandingan

4.6.1. Hasil Pengujian

Model yang sudah terlatih disimpan ke dalam file berformat h5. Pengujian dilakukan terhadap model terlatih untuk melakukan segmentasi terhadap citra *X-Ray* yang tidak digunakan untuk data latih.



Gambar 4. 19. Hasil pengujian model terhadap citra *X-Ray*


Pada gambar 4.19 dapat dilihat hasil dari pengujian model terhadap citra *X-Ray*. Gambar A merupakan citra *X-Ray* yang tidak digunakan sebagai data latih, pada citra tersebut tampak paru-paru kiri terdapat area berkabut putih (lingkaran

warna kuning). Model menghasilkan segmentasi area paru-paru kanan dan paru-paru kiri pada gambar B, dari hasil segmentasi tersebut dibuat sebuah batas tepi yang ditampakkan pada gambar C. Dengan memanfaatkan batas tepi yang telah diprediksi oleh model tersebut dilakukan cropping terhadap citra *X-Ray* dan menghasilkan gambar paru-parunya saja seperti pada gambar D. Terlihat pula pada gambar D tersebut bahwa area berkabut putih tetap diprediksi sebagai area paru-paru (lingkaran kuning).

4.6.2. Performa Model

Hasil dari pelatihan model segmentasi U-Net tertinggi menunjukkan performa IoU 97,29% dan akurasi 98,55% didapatkan dari pelatihan dengan konfigurasi penambahan lapisan Dropout 20% pada tahap encoder (*contracting path*). Namun saat dilakukan validasi hanya menghasilkan performa 95,95% untuk IoU sehingga hal tersebut menunjukkan terjadinya *overfitting* pada model dengan nilai perbedaan mencapai 1,34% IoU validasi lebih rendah daripada IoU pelatihan.

Untuk mengurangi *overfitting* dilakukan penambahan lapisan Dropout dan menambahkan lapisan Dropout pada bagian *upsampling* atau *expansion path*. Pada penambahan Dropout 30% menunjukkan performa model berkurang menjadi hanya 95,04% - 96,07% untuk IoU pada pelatihan dan 95,24% - 95,66% untuk IoU pada validasinya, ketika dihitung perbedaan antara nilai validasi dengan nilai pelatihan didapatkan rata-rata 0,2% perbedaan IoU validasi dengan IoU pelatihan. Angka 0,2% tersebut menunjukkan bahwa tidak terjadi *overfitting* pada model.




Gambar 4. 20. Grafik hasil pelatihan dan validasi dari model

Terlihat pada gambar 4.21 bahwa model dapat dilatih dengan baik menggunakan jumlah epoch 100. Grafik antara hasil pelatihan selaras dengan grafik ujiannya. Pada gambar paling kiri menunjukkan grafik perkembangan nilai akurasi piksel selama pelatihan (garis biru) dan hasil validasi akurasi (garis kuning). Gambar kedua menunjukkan perkembangan nilai dari fungsi loss yang selaras antara pelatihan (garis merah) dengan nilai loss validasi (garis hijau). Untuk gambar ketiga merupakan grafik perkembangan nilai IoU selama pelatihan (garis merah) dan nilai IoU validasi (garis kuning).

4.6.3. Perbandingan dengan Penelitian Sebelumnya

Pada penelitian sebelumnya (Yang, 2018) yang menggunakan metode pengolahan citra konvensional teknik deteksi tepi telah terjadi kegagalan dalam melakukan segmentasi batas area paru-paru pada gambar *X-Ray* dengan paru-paru yang tidak normal. Terlihat pada hasil deteksi batas paru-paru penelitian tersebut terjadi kegagalan pada gambar ke-9 dan batas paru-paru terlihat tidak wajar pada gambar ke 4, 6, 7 dan 8. Pada hasil segmentasi paru-paru menggunakan model segmentasi U-Net (gambar 4.21) paru-paru dapat tersegmentasi dengan baik, terlihat area paru-paru dengan tegas dan tepi yang halus. Paru-paru yang tidak

normal pada gambar ke-1 dan ke-2 tetap dapat tersegmentasi meskipun banyak area yang terlihat rusak seperti tertutup kabut putih tebal (Gambar 4.21).



Gambar 4. 21. Perbandingan Hasil Uji dari Model U-Net (B) dengan Model SED (A)

Penelitian menggunakan teknik deteksi tepi (Yang, 2018) bertujuan untuk mendeteksi segmen dari paru-paru menggunakan beberapa tahap yang diawali dengan deteksi tepi, kemudian memanfaatkan hasil deteksi tepi tersebut untuk menentukan segmen paru-paru menggunakan teknik *Ultra Contour Map* (UCM) dan *marker-controlled watershed transform* (MWT). Metode deteksi tepi juga digunakan pada penelitian (Zotin, 2019) yang mencoba untuk melakukan segmentasi paru-paru dengan menambahkan *Otsu Thresholding*. Selain mencoba segmentasi, penelitian tersebut melakukan klasifikasi dari hasil segmentasi yang telah dilakukan menggunakan PNN (*Probability Neural Network*) untuk memprediksi paru-paru tersebut normal atau tidak. Untuk penelitian segmentasi paru-paru menggunakan teknik *Deep Learning* dilakukan dengan menggunakan arsitektur CNN AlexNet (Souza, 2019). Dari ketiga penelitian tersebut memiliki

tujuan yang sama dengan penelitian yang dilakukan yaitu untuk melakukan segmentasi paru-paru dari citra *X-Ray* dada, hanya untuk penelitian Zotin dilanjutkan dengan klasifikasi.

Percobaan segmentasi oleh Yang (2018) menggunakan dataset publik dari JSRT yang mana dataset tersebut telah dipublikasikan sudah cukup lama pada tahun 2000, sedangkan untuk percobaan oleh Zotin dan Souza (2019) menggunakan dataset yang sama dengan penelitian yang dilakukan. Dataset dari publikasi (Jaeger, 2014) digunakan untuk melatih model segmentasi. Dataset tersebut memiliki keunggulan karena lebih baru daripada dataset JSRT dan memiliki beragam kondisi paru-paru yang diakibatkan oleh proses penyakit Tuberkulosis, selain itu dataset tersebut menyertakan hasil anotasi masking paru-paru yang dibuat dengan supervisi dari ahli radiologi.

Metode pengujian yang dilakukan pada penelitian pertama (Yang, 2018) dan penelitian yang kedua (Zotin, 2019) menggunakan perhitungan *Jaccard Index* dan *Dice Similarity Coefficient (DSC)*. Untuk metode pengujian pada penelitian menggunakan *Deep Learning* (Souza, 2019) menggunakan perhitungan *Jaccard Index* dan Akurasi Piksel. Pada penelitian ini dilakukan evaluasi menggunakan perhitungan *Jaccard Index* atau disebut juga IoU yang akan dibandingkan dengan ketika penelitian sebelumnya dan Akurasi Piksel sebagai perbandingan terhadap metode segmentasi yang sama-sama menggunakan *Deep CNN*.

Sebagai perbandingan terhadap model-model yang pernah diusulkan pada penelitian sebelumnya maka hasil dari performa model U-Net ditampilkan ke dalam tabel 4.8. Pada tabel tersebut dapat dilihat bahwa performa dari model segmentasi

menggunakan U-Net dapat mengungguli performa metode *Edge Detection + Otsu*, AlexNet dan juga *Structured Edge Detection*.

Tabel 4. 8. Perbandingan performa model

Metode	IoU	Akurasi	Dataset	Tahapan
SED (Yang, 2018)	94,6%	-	JSRT, CRASS	Segmentasi
ED+Otsu (Zotin, 2019)	91,5%	-	MC	Segmentasi + Klasifikasi
AlexNet (Souza, 2019)	88,07%	96,97%	MC	Segmentasi + Rekonstruksi
U-Net (penelitian ini)	95,46%	98,26%	MC	Segmentasi
U-Net + DO (penelitian ini)	97,29%	98,55%	MC	Segmentasi





Dari beberapa penelitian sebelumnya tidak seluruhnya melakukan penelitian untuk mencari batasan paru-paru saja. Penelitian segmentasi paru-paru menggunakan deteksi tepi dan thresholding dilanjutkan dengan klasifikasi menggunakan PNN (Zotin, 2019), penelitian segmentasi menggunakan metode *Deep Learning* Alex-Net (Souza, 2019) dilanjutkan dengan proses rekonstruksi untuk memperbaiki bidang paru-paru yang hilang di dalam prediksi awal. Penelitian segmentasi menggunakan *Structured Edge Detection* (SED) hanya melakukan percobaan sampai menghasilkan bidang paru-paru yang diprediksi (Yang, 2018), penelitian yang dilakukan tidak melanjutkan percobaan setelah model dapat melakukan segmentasi batas paru-paru.

Di dalam tabel 4.8 dapat dilihat bahwa model segmentasi menggunakan U-Net dapat mengungguli model segmentasi lainnya. Dengan adanya tambahan lapisan Dropout (DO) yang dilakukan sebagai kontribusi pada penelitian ini ternyata dapat meningkatkan performa model menjadi lebih baik. Akurasi model selisih 0,29% lebih baik setelah penambahan DO, sedangkan untuk nilai IoU


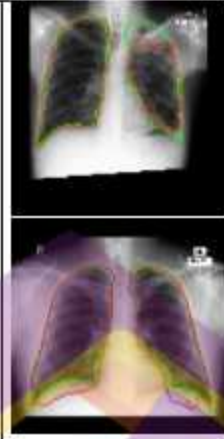


(*Intersection over Union*) yang dihasilkan setelah adanya penambahan DO meningkat 1,83% menjadi 97,29%. Dari hasil tersebut menunjukkan bahwa penambahan DO pada pelatihan model segmentasi menggunakan Deep CNN arsitektur U-Net dapat meningkatkan performa model.

4.7. Output Segmentasi

Tabel 4. 9. Visualisasi Output Segmentasi

Penelitian	Output	Kekurangan	Metode	IoU
Yang, 2018			Deteksi Tepi	94,6%
Zotin, 2019			Deteksi Tepi	91,5%

Tabel 4. 9. (Lanjutan)

Souza, 2019			CNN AlexNet + ResNet-18	88,07%
Penelitian Ini			U-Net	97,29%

Pada tabel 4.9 menunjukkan hasil output dari segmentasi penelitian menggunakan deteksi tepi (Yang et al., 2018) terdapat kekurangan belum bisa melakukan segmentasi apabila gambaran paru tertutup oleh kabut putih. Selain itu terjadi kegagalan segmentasi pada kondisi gambar tertentu. Untuk hasil dari metode pemrosesan citra lain adalah dengan thresholding dan deteksi tepi (Zotin et al., 2019) menghasilkan segmentasi dengan batas kontur paru-paru bergelombang

(warna merah), yang mana hal ini tidak sesuai dengan aslinya bahwa batas tepi paru-paru tidak bergelombang (warna hijau). Kedua masalah pada penelitian tersebut tidak muncul pada hasil output dengan metode CNN.

Pada hasil yang tampak dari metode menggunakan CNN AlexNet (Souza et al., 2019) dan metode CNN U-Net pada penelitian ini menunjukkan kontur batas paru-paru yang tidak bergelombang (warna merah) mendekati kontur batas dari *Ground Truth*-nya (warna hijau). Namun pada hasil output AlexNet terdapat kegagalan pada deteksi paru-paru yang tertutup kabut putih. Hal tersebut dapat diatasi dengan teknik rekonstruksi yang dilakukan menggunakan ResNet dan berhasil. Akan tetapi tidak seluruh paru-paru berhasil disegmentasi dengan baik setelah adanya penambahan rekonstruksi bahkan model mendeteksi area bukan paru-paru sebagai area paru-paru terlihat pada gambar garis warna merah ada yang melebihi batas cukup jauh dari garis warna hijau yang mengakibatkan nilai akhir IoU model hanya 88,07%. Pada penelitian ini hal tersebut tidak terjadi, hampir seluruh segmentasi berhasil dengan baik ditunjukkan dengan nilai IoU akhir 97,29%. Model pada penelitian ini berhasil mendeteksi paru-paru meskipun tertutup kabut putih.

BAB V

PENUTUP

5.1. Kesimpulan

Model yang dilatih menggunakan teknik *Deep Learning* dengan arsitektur CNN U-Net dapat digunakan untuk melakukan segmentasi area paru-paru pada citra *X-Ray* dada. Segmentasi tidak hanya berhasil pada gambaran paru-paru normal atau tanpa penyakit, namun juga berhasil terhadap gambaran paru-paru pada pasien dengan diagnosa klinis tuberkulosis.

Model segmentasi dengan arsitektur U-Net dapat disusun menggunakan bahasa pemrograman python dan memanfaatkan *library* yang sudah tersedia secara bebas untuk dipergunakan. *Library* utama yang dimanfaatkan dalam pelatihan model segmentasi U-Net pada bahasa python adalah keras dan tensorflow. Tensorflow dapat digunakan dengan memanfaatkan kemampuan pengolahan 3D dari perangkat keras kartu grafis N-Vidia yang memiliki *Cuda Core*.

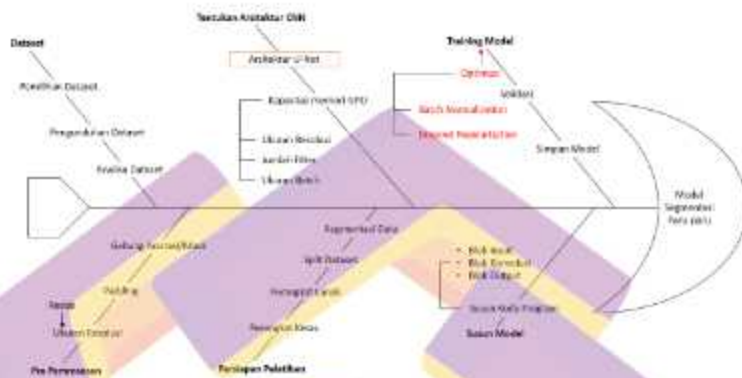
5.1.1. Menentukan set hyperparameter yang optimal untuk melatih model segmentasi paru-paru pada citra *X-Ray* dada menggunakan Deep CNN arsitektur U-Net

Untuk melakukan segmentasi paru-paru menggunakan *Deep Learning* diperlukan dataset yang terdiri dari citra *X-Ray* dada beserta anotasi *ground truth masking* paru-parunya. Model segmentasi dapat dilatih menggunakan arsitektur U-Net dengan tahapan mulai dari persiapan dataset, pra-pemrosesan dataset, pembacaan dataset input, pelatihan model, validasi dan pengujian.

Pelatihan model segmentasi dengan arsitektur U-Net dapat dilakukan hanya dengan jumlah dataset yang terbatas, sebagaimana dilakukan dalam penelitian ini hanya menggunakan 138 set data citra *X-Ray* dada beserta anotasi masking paru-parunya. Pembuatan sistem otomatis untuk melakukan segmentasi paru-paru menggunakan metode Deep Learning berbeda dengan metode pengolahan citra konvensional, perbedaan paling mendasar adalah pada tahap pelatihan dimana komputer dirancang untuk mempelajari sendiri fitur-fitur yang ada di dalam citra *X-Ray* dada. Dengan demikian output dari metode Deep CNN di dalam tugas segmentasi adalah penentuan kelas dari setiap piksel di dalam citra, dalam hal ini sebuah citra *X-Ray* dada memiliki piksel dengan kelas biner yaitu kelas paru-paru dan kelas bukan paru-paru.

Penentuan set hyperparameter dilakukan dengan mencoba berbagai konfigurasi nilai seperti jumlah batch, jumlah filter, jumlah epoch, jumlah langkah setiap epoch dan learning rate. Khusus untuk menentukan nilai learning rate dilakukan percobaan dengan menggunakan metode penjadwalan atau learning rate scheduler. Set hyperparameter yang optimal pada penelitian ini adalah jumlah batch 32, jumlah filter 32, step tiap epoch 100 dan jumlah epoch pada rentang 150 hingga 200.

5.1.2. Modifikasi Deep CNN arsitektur U-Net untuk meningkatkan performa segmentasi paru-paru pada citra *X-Ray* dada



Gambar 5. 1. Diagram Kerangka Kerja Segmentasi Paru-paru menggunakan Deep Learning

Secara umum kerangka kerja dalam membuat model segmentasi paru-paru dari citra *X-Ray* dada menggunakan metode *Deep Learning* dapat dilihat pada gambar 5.1. Secara prinsip untuk dapat membuat model segmentasi dengan DL harus ada dataset yang banyak, namun untuk CNN dengan arsitektur U-Net dapat melakukan pembelajaran meskipun hanya dengan dataset terbatas, hal ini dikarenakan adanya teknik augmentasi yang dapat diterapkan pada arsitektur tersebut.

Pada penelitian ini modifikasi dilakukan dengan menambahkan regularisasi berupa *Dropout* lapisan. Setiap langkah konvolusi menghasilkan jumlah lapisan *feature map* tertentu, kemudian selanjutnya dilakukan pengurangan atau dropout secara acak sebagian lapisan peta fitur tersebut. Jumlah pengurangan tidak asal dilakukan namun dicari berapa persen pengurangan dari keseluruhan lapisan. Dari

hasil percobaan didapatkan pengurangan atau dropout terbaik terjadi pada rentang 30% hingga 40%.

5.1.3. Nilai akurasi piksel dan nilai Irisan segmentasi paru-paru pada citra X-Ray dada menggunakan Deep CNN arsitektur U-Net

Performa dari model segmentasi dengan arsitektur U-Net dipengaruhi oleh beberapa *hyperparameter* yaitu jumlah filter yang digunakan, jumlah *epochs* pada saat pelatihan, jumlah *steps per epoch* dan *learning rate*. Hasil dari performa model segmentasi U-Net dapat mengungguli hasil dari segmentasi pada penelitian sebelumnya, bahkan setiap gambar *X-Ray* dada yang mengalami kerusakan atau perubahan morfologi tetap dapat disegmentasi dengan baik dan dapat menampilkan batas paru-paru yang rasional.

Model segmentasi U-Net yang telah dilatih pada penelitian ini menunjukkan performa yang lebih baik daripada model-model segmentasi sebelumnya. Model U-Net menunjukkan nilai akurasi model 98,26% untuk tingkat akurasi pikselnya dan nilai IoU 95,46% untuk tingkat irisan tumpang tindihnya. Nilai IoU tersebut mengungguli nilai IoU dari model segmentasi menggunakan SED dengan nilai 95,2%. Dengan penambahan regularisasi dropout performa segmentasi meningkat menjadi 98,55% untuk akurasi pikselnya dan 97,28% untuk IoU.

5.2. Saran

Pada penelitian ini belum dilakukan percobaan untuk memanfaatkan hasil dari segmentasi paru-paru ke dalam tugas klasifikasi. Apakah citra *X-Ray* dada yang telah disegmentasi akan menjadikan klasifikasi penyakit pada paru-paru lebih baik

atau tidak. Untuk penelitian berikutnya dapat dilakukan klasifikasi penyakit paru-paru yang dilakukan menggunakan inputan dari hasil segmentasi paru-paru terhadap citra *X-Ray* dada.

Untuk dapat menambah manfaat terhadap proses pelayanan di dalam Rumah Sakit diperlukan integrasi model yang telah dilatih ke dalam Sistem Informasi Rumah Sakit. Sebelumnya dapat dilakukan analisa sistem terlebih dahulu dengan meneliti arsitektur yang baik dalam rangka integrasi antara sistem Kecerdasan Buatan dengan Sistem Informasi Rumah Sakit. Selain itu untuk dapat membuat model segmentasi yang lebih baik lagi menggunakan metode *Deep Learning* maka sebaiknya Rumah Sakit membuat dataset anotasi paru-paru yang terkini oleh spesialis radiologi agar kemampuan dari komputer lebih seiring dengan perkembangan penyakit saat ini.



DAFTAR PUSTAKA

- Agrawal, T., Choudhary, P. Segmentation and classification on chest radiography: a systematic survey. *Vis Comput* 39, 875–913 (2023). <https://doi.org/10.1007/s00371-021-02352-7>
- Asipong, K., Gabbualoy, S., and Phasukkit, P., "Coronavirus infected lung CT scan image segmentation using *Deep Learning*.". (2021). 18th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON), Chiang Mai, Thailand, 2021, pp. 773–776, doi: 10.1109/ECTI-CON51831.2021.9454944.
- Badrinarayanan, V et al. 2017. "SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation". *IEEE Transactions on Pattern Analysis and Machine Intelligence* (Volume: 39, Issue: 12, 01 December 2017) 2481 - 2495. <https://doi.org/10.1109/TPAMI.2016.2644615>.
- Candemir, S., & Antani, S. (2019). A review on lung boundary detection in chest X-rays. *International Journal of Computer Assisted Radiology and Surgery*, 14(4), 563–576. <https://doi.org/10.1007/s11548-019-01917-1>
- Fatimah, N., (2022). Prevalensi 10 Penyakit Terbanyak yang Memerlukan Foto *X-Ray* Thorax Radiologi Diagnostik di RSUP Dr. Wahidin Sudirohusodo pada tahun 2019. Skripsi-S1, Universitas Hasanuddin, <http://repository.unhas.ac.id/id/eprint/1326/>
- Jaeger S, Candemir S, Antani S, Wang YX, Lu PX, Thoma G. Two public chest *X-Ray* datasets for computer-aided screening of pulmonary diseases. *Quant Imaging Med Surg* 2014;4(6):475-477. doi: 10.3978/j.issn.2223-4292.2014.11.20
- Kim, M., & Lee, B. D. (2021). Automatic lung segmentation on chest x-rays using self-attention deep neural network. *Sensors* (Switzerland), 21(2), 1–12. <https://doi.org/10.3390/s21020369>
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., van der Laak, J. A. W. M., van Ginneken, B., & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60–88. <https://doi.org/https://doi.org/10.1016/j.media.2017.07.005>
- Mardiyah, A., & Harjoko, A. (2011). Metode Segmentasi Paru-paru dan Jantung Pada Citra *X-Ray* Thorax. *Ijeis*, 1(2), 35–44.

- Moses, D.A. (2021), Deep learning applied to automatic disease detection using chest *X-Rays*. *J Med Imaging Radiat Oncol*, 65: 498-517. <https://doi.org/10.1111/1754-9485.13273>
- Nishio, M., Fujimoto, K., & Togashi, K. (2021). Lung segmentation on chest *X-Ray* images in patients with severe abnormal findings using deep learning. *International Journal of Imaging Systems and Technology*, 31(2), 1002–1008. <https://doi.org/10.1002/ima.22528>
- Rajkomar, A., Lingam, S., Taylor, A.G. et al. High-Throughput Classification of Radiographs Using Deep Convolutional Neural Networks. *J Digit Imaging* 30, 95–101 (2017). <https://doi.org/10.1007/s10278-016-9914-9>.
- Saad, M. N., Muda, Z., Ashaari, N. S., & Hamid, H. A. (2014). Image segmentation for lung region in chest *X-Ray* images using edge detection and morphology. *Proceedings - 4th IEEE International Conference on Control System, Computing and Engineering, ICCSCE 2014*, September 2021, 46–51. <https://doi.org/10.1109/ICCSCE.2014.7072687>
- Simonyan K, Zisserman A (2014) Very deep convolutional networks for large-scale image recognition. <http://arxiv.org/abs/1409.1556>
- Souza JC, Diniz JOB, Ferreira JL, Silva GLF, Silva AC, Paiva AC. (2019). An Automatic Method for Lung Segmentation and Reconstruction in Chest *X-Ray* using Deep Neural Networks. *Computer Methods and Programs in Biomedicine* 177 (2019) 285–296. Doi: 10.1016/j.cmpb.2019.06.005
- Spilisbury, T., & Camps, P. (2019). Don't ignore Dropout in Fully Convolutional Networks. <http://arxiv.org/abs/1908.09162>
- Suyanto, Ramadhani, K.N., Mandala, S., 2019, *Deep Learning: Modernisasi Machine Learning untuk Big Data*, Informatika, Bandung
- Wang, M., & Deng, W. (2018). Deep visual domain adaptation: A survey. *Neurocomputing*, 312, 135–153. <https://doi.org/10.1016/j.neucom.2018.05.083>
- World Health Organization. *Global Health Estimates: The Top 10 Causes of Death, 2000–2019*. World Health Organization, 2020.
- Xu, M., Qi, S., Yue, Y., Teng, Y., Xu, L., Yao, Y., & Qian, W. (2019). Segmentation of lung parenchyma in CT images using CNN trained with the clustering algorithm generated dataset 08 *Information and Computing Sciences* 0801 *Artificial Intelligence and Image Processing* Robert Koprowski. *BioMedical Engineering Online*, 18(1), 1–22. <https://doi.org/10.1186/s12938-018-0619-9>
- Yang W, Liu Y, Lin L, Yun Z, Lu Z, Feng Q, Chen W. Lung Field Segmentation in Chest Radiographs From Boundary Maps by a Structured Edge Detector.

IEEE J Biomed Health Inform. 2018 May;22(3):842-851. doi: 10.1109/JBHI.2017.2687939. Epub 2017 Mar 27. PMID: 28368835.

Yu, T., & Zhu, H. (2020). Hyper-Parameter Optimization: A Review of Algorithms and Applications. ArXiv, abs/2003.05689.

Zotin, A., Hamad, Y., Simonov, K., & Kurako, M. (2019). ScienceDirect ScienceDirect Lung boundary detection for chest *X-Ray* images classification based Lung boundary detection for chest *X-Ray* images classification based on GLCM and probabilistic neural networks on GLCM and probabilistic neural networks. *Procedia Computer Science*, 159, 1439–1448. <https://doi.org/10.1016/j.procs.2019.09.314>

