

**Deteksi Area Lesi Terinfeksi pada Kasus Pra-Kanker  
Serviks menggunakan Pendekatan Semantik Segmentasi  
dan *Faster-RCNN***

**TUGAS AKHIR**

**Diajukan Untuk Melengkapi Salah Satu Syarat**

**Memperoleh Gelar Sarjana Komputer**



**OLEH :**

**Jarna Ajda**

**09011181823013**

**JURUSAN SISTEM KOMPUTER  
FAKULTAS ILMU KOMPUTER  
UNIVERSITAS SRIWIJAYA**

**2022**

## HALAMAN PENGESAHAN

# Deteksi Area Lesi Terinfeksi pada Kasus Pra-Kanker Serviks menggunakan Pendekatan Semantik Segmentasi dan *Faster-RCNN*

## TUGAS AKHIR

Program Studi Sistem Komputer  
Jenjang S1

Oleh

Jarna Ajda  
09011181823013

Palembang, 7 juli 2022

Mengetahui,

Ketua Jurusan Sistem Komputer

Pembimbing Tugas Akhir



*Jarna*  
**Dr. Ir. H. Sukemi, M.T.**  
NIP. 19661203 200604 1 001

*Siti Nurmaini*  
**Prof. Dr. Ir. Siti Nurmaini, M.T.**  
NIP. 19690802 199401 2 001

## HALAMAN PERSETUJUAN

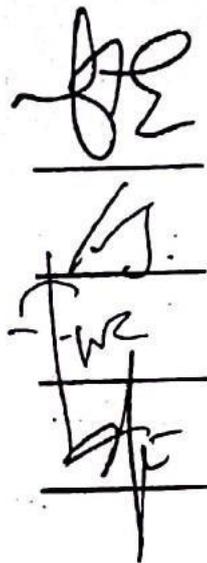
Telah diuji dan lulus pada:

Hari : Kamis

Tanggal : 16 Juni 2022

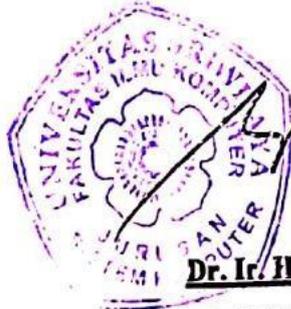
Tim Penguji :

1. Ketua : Dr. Ir. Bambang Tutuko, M.T.
2. Sekretaris : Iman Saladin B. Azhar, M.MSI
3. Penguji : Firdaus, M.Kom.
4. Pendamping : Prof. Dr. Ir. Siti Nurmalni, M.T.



Mengetahui,

Ketua Jurusan Sistem Komputer



Dr. Ir. H. Sukemi M.T.

NIP. 196612032006041001

## HALAMAN PERNYATAAN

Yang bertanda tangan dibawah ini:

Nama : Jarna Ajda  
NIM : 09011181823013  
Judul : Deteksi Area Lesi Terinfeksi pada Kasus Pra-Kanker Serviks menggunakan Pendekatan Semantik Segmentasi dan Faster-RCNN

Hasil Pengecekan Software *iThenticate/Turnitin* : 6 %

Menyatakan bahwa laporan tugas akhir saya merupakan hasil karya sendiri dan bukan hasil penjiplakan atau plagiat. Apabila ditemukan unsur penjiplakan atau plagiat dalam laporan tugas akhir ini, maka saya bersedia menerima sanksi akademik dari universitas Sriwijaya.

Demikian, pernyataan ini saya buat dalam keadaan sadar dan tidak dipaksakan.



Indralaya, 16 Juni 2022



**Jarna Ajda**

**09011181823013**

## KATA PENGANTAR

Assalamu'alaikum Wr.Wb.

Puji syukur Alhamdulillah penulis panjatkan atas kehadiran Allah SWT yang telah memberikan karunia dan rahmat-Nya, sehingga penulis dapat menyelesaikan penulisan Proposal Tugas Akhir ini yang berjudul **“Deteksi area Lesi Terinfeksi pada Kasus Pra-kanker serviks menggunakan Pendekatan Semantik Segmentasi dan *Faster-RCNN*”**.

Dalam laporan ini penulis menjelaskan mengenai pemodelan untuk identifikasi dan Deteksi area lesi terinfeksi pada gambar pra-kanker serviks dengan disertai data-data yang diperoleh penulis saat melakukan penelitian dan pengujian data. Penulis berharap agar tulisan ini dapat bermanfaat bagi orang banyak.

Pada kesempatan ini penulis ingin mengucapkan terima kasih kepada beberapa pihak atas ide dan saran serta bantuannya dalam menyelesaikan penulisan Proposal Tugas Akhir ini. Oleh karena itu, penulis ingin mengucapkan rasa syukur kepada Allah SWT dan terimakasih kepada yang terhormat :

1. Allah SWT, yang telah memberikan rahmat dan karunia-Nya sehingga saya dapat menyelesaikan penulisan Proposal Tugas Akhir ini dengan baik dan lancar.
2. Orang tua saya tercinta yang telah membesarkan saya dengan penuh kasih sayang dan selalu mengajarkan saya dalam berbuat hal yang baik. Terimakasih untuk segala do'a, motivasi dan dukungannya baik moril, materil maupun spritual selama ini, serta kakak dan adik saya terima kasih atas segala bantuan dan dukungannya.
3. Bapak Jaidan Jauhari, S.Pd., M.T., selaku Dekan Fakultas Ilmu Komputer Universitas Sriwijaya.
4. Bapak Dr. Ir. H. Sukemi, M.T., selaku Ketua Jurusan Sistem Komputer Fakultas Ilmu Komputer Universitas Sriwijaya.

5. Ibu Prof. Dr. Ir. Siti Nurmaini, M.T. selaku Dosen Pembimbing Tugas Akhir yang telah berkenan meluangkan waktunya guna membimbing, memberikan saran dan motivasi serta bimbingan terbaik untuk penulis dalam menyelesaikan Tugas Akhir ini. Dan selaku Pembimbing Akademik Jurusan Sistem Komputer.
6. Kak Naufal, Mbak Ade, Mbak Annisa, Pak firdausa dan semua teman yang bergabung dalm grup riset citra IsysRg Batch III yang turut membantu memberi penjelasan dan arahan serta nasehat.
7. Mbak Renny selaku admin Jurusan Sistem Komputer yang telah membantu mengurus seluruh berkas.
8. Semua teman-teman yang telah mensupport saya dari semester awal hingga saat ini, serta kakak tingkat yang telah membantu saya dalam memberi arahan selama kuliah ataupun penulisan tugas akhir.
9. Terima kasih juga kepada Bella Apriani, Haqiqi Oktaviani, Masayu Nadila Maharani, Syerpri Windriya Kusuma Wati, dan Yusdiansya Putra telah membantu saya selama perkuliahaan dan membantu dalam pemberkasan
10. Dan semua pihak yang telah membantu.

Penulis menyadari bahwa laporan ini masih sangat jauh dari kata sempurna. Untuk itu kritik dan saran yang membangun sangatlah diharapkan penulis. Akhir kata penulis berharap, semoga proposal tugas akhir ini bermanfaat dan berguna bagi khalayak.

Wassalamu'alaikum Wr. Wb.

Indralaya, 16 Juni 2022

Penulis,



Jarna Ajda  
NIM. 09011181823013

# **DETECTION OF INFECTED LESSIONS IN CASE OF PRE-CERVICAL CANCER USING SEMANTIC SEGMENTATION AND FASTER-RCNN APPROACHES**

**JARNA AJDA (09011181823013)**

*Computer Engineering Department, Computer Science Faculty, Sriwijaya University*

Email: [jarnaajda985@gmail.com](mailto:jarnaajda985@gmail.com)

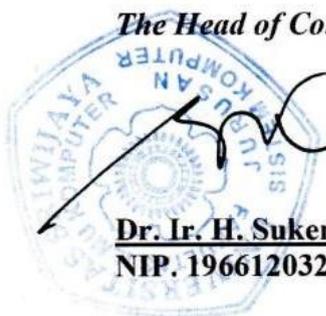
## **ABSTRACT**

*Cervical pre-cancer is the initial occurrence of cancer and referred to as cervical lesions and carcinoma (CA). Before the formation of pre-cancerous cells (lesions), abnormal cells appear on the cervix which is the prelude to cervical pre-cancer. The squamous columnar junction (SSK) is a transitional area of the vaginal mucosa and cervical mucosa that looks like a distinct line between areas of columnar epithelium and squamous. A computer-assisted diagnostic system solves these problems, namely medical image segmentation and object detection. This study uses the Convolutional Neural Network (CNN) method, namely segmentation using U-Net architecture, V-Net, and detection using Faster R-CNN architecture. The initial data and augmented data resulted in 24 models from the U-Net architecture, 24 models from the V-Net architecture, and 12 models from the Faster R-CNN architecture using data from the best model results obtained from segmentation detection on the U-Net architecture. The best model from U-Net CA (II) which gets the highest evaluation results is 99.34% Pixel Accuracy, 94.16% Intersection Over Union (IoU), and 93.22% F1 Score. Lesion (II) 98.83% Pixel Accuracy, 94.48% Intersection Over Union (IoU), and 93.29% F1 Score. While the best model of the V-Net CA (II) architecture got the highest evaluation results of 99.32 Pixel Accuracy, 93.85 Intersection Over Union (IoU), and 93.03 F1 Score. Lesions (II) 99.00% Pixel Accuracy, 94.70% Intersection Over Union (IoU), and 94.09% F1 Score. The best model from Faster R-CNN gets the highest evaluation result of mAP with a value of 86.07%. Results Based on the experiment of segmentation using U-Net and V-Net, the U-Net segmentation result model is better than the model obtained from segmentation using V-Net.*

**Keywords:** *Cervical pre-cancer, cervical carcinoma, Lesion, Squamous columnar junction, Augmentation, Segmentation, Detection, U-Net, V-Net, Faster R-CNN*

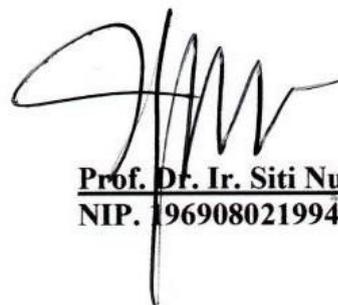
**Acknowledged By,**

**The Head of Computer Systems Department**



**Dr. Ir. H. Sukemi M.T.**  
**NIP. 196612032006041001**

**Final Project Advisor**



**Prof. Dr. Ir. Siti Nurmaini, M.T.**  
**NIP. 196908021994012001**

# DETEKSI AREA LESI TERINFEKSI PADA KASUS PRA-KANKER SERVIKS MENGGUNAKAN PENDEKATAN SEMANTIK SEGMENTASI DAN FASTER-RCNN

JARNA AJDA (09011181823013)

Jurusan Sistem Komputer, Fakultas Ilmu Komputer, Universitas Sriwijaya  
Email: [jarnaajda985@gmail.com](mailto:jarnaajda985@gmail.com)

## ABSTRAK

Pra-kanker serviks merupakan awal terjadinya sebuah kanker dan disebut sebagai lesi dan Karsinoma Serviks (KS). Sebelum terbentuknya sel – sel pra kanker (lesi), muncul sel – sel abnormal pada leher rahim yang merupakan awalan terjadinya pra-kanker serviks. Sambungan skuamosa kolumnar (SSK) merupakan daerah peralihan mukosa vagina dan mukosa servikalis yang terlihat seperti garis yang berbeda antara daerah pada kolumnar epitel dan skuamosa. Sistem diagnosis bantuan dari komputer sebagai solusi untuk masalah tersebut, yaitu segmentasi citra medis dan deteksi objek. Penelitian ini menggunakan metode Convolutional Neural Network (CNN) yaitu segmentasi menggunakan arsitektur U-Net, V-Net dan deteksi menggunakan arsitektur Faster R-CNN. Data awal dan data augmentasi menghasilkan 24 model dari arsitektur U-Net, 24 model dari arsitektur V-Net dan 12 model dari arsitektur Faster R-CNN yang menggunakan data dari hasil model terbaik yang didapatkan dari deteksi segmentasi pada arsitektur U-Net. Model terbaik dari U-Net CA (II) yang mendapatkan hasil evaluasi tertinggi 99,34% *Pixel Accuracy*, 94,16% *Intersection Over Union* (IoU) dan 93,22% *F1 Score*. Lesi (II) 98.83% *Pixel Accuracy*, 94.48% *Intersection Over Union* (IoU) , dan 93.29% *F1 Score*. Sedangkan model terbaik dari arsitektur V-Net CA (II) mendapatkan hasil evaluasi tertinggi 99,32 *Pixel Accuracy*, 93,85 *Intersection Over Union* (IoU) dan 93,03 *F1 Score*. Lesi ( II ) 99.00% *Pixel Accuracy*, 94.70% *Intersection Over Union* (IoU), dan 94.09% *F1 Score*. Model terbaik dari Faster R-CNN mendapatkan hasil evaluasi tertinggi mAP dengan nilai 86.07%. Berdasarkan hasil percobaan dari segmentasi yang menggunakan U-Net dan V-Net, model hasil segmentasi U-Net lebih baik dibandingkan model yang didapatkan dari segmentasi yang menggunakan V-Net.

**Kata Kunci:** Pra-kanker serviks, Karsinoma Serviks , Lesi, Sambungan skuamosa kolumnar, Augmentasi, Segmentasi, Deteksi, U-Net, V-Net, Faster R-CNN

Mengetahui,

Ketua Jurusan Sistem Komputer



**Dr. Ir. H. Sukemi M.T.**  
NIP. 196612032006041001

Pembimbing Tugas Akhir



**Prof. Dr. Ir. Siti Nurmaini, M.T.**  
NIP. 196908021994012001

## DAFTAR ISI

	<b>Halaman</b>
<b>HALAMAN PENGESAHAN</b> .....	<b>ii</b>
<b>HALAMAN PERSETUJUAN</b> .....	<b>iii</b>
<b>HALAMAN PERNYATAAN</b> .....	<b>iv</b>
<b>KATA PENGANTAR</b> .....	<b>v</b>
<b>ABSTRACT</b> .....	<b>vii</b>
<b>ABSTRAK</b> .....	<b>viii</b>
<b>DAFTAR ISI</b> .....	<b>ix</b>
<b>DAFTAR GAMBAR</b> .....	<b>xiv</b>
<b>DAFTAR TABEL</b> .....	<b>xvii</b>
<b>DAFTAR LAMPIRAN</b> .....	<b>xviii</b>
<b>BAB I PENDAHULUAN</b> .....	<b>1</b>
1.1    Latar Belakang .....	1
1.2    Rumusan masalah dan Tujuan.....	3
1.2.1    Rumusan Masalah .....	3
1.2.2    Tujuan .....	3
1.3    Manfaat dan Batasan Masalah.....	4
1.3.1    Manfaat .....	4
1.3.2    Batasan Masalah.....	4
1.4    Metodologi Penulisan.....	5
1.4.1    Metode Studi Pustaka dan Literatur.....	5
1.4.2    Metode Konsultasi.....	5
1.4.3    Metode Pembuatan Model.....	5
1.4.4    Metode Pengujian dan Validasi .....	6
1.4.5    Metode hasil dan Analisa .....	6
1.4.6    Metode Penarikan Kesimpulan dan Saran .....	6
1.5    Sistematika Penulisan.....	6
<b>BAB II TINJAUAN PUSTAKA</b> .....	<b>8</b>
2.1    Serviks.....	8
2.2    Pra-kanker Serviks .....	8
2.2.1 <i>Cervical Carcinoma (CA)</i> .....	8
2.2.2    Sambungan Skuamosa Kolumnar.....	9
2.2.3    Lesi Pra-kanker Seviks .....	9
2.3    Servikografi.....	10

2.4	Citra Digital.....	11
2.4.1	Citra RGB.....	11
2.4.2	Citra <i>Grayscale</i> .....	11
2.5	Machine Learning .....	12
2.6	Deep Learning.....	13
2.7	Convolution Neural Network .....	13
2.8	U-Net.....	14
2.9	V-Net.....	15
2.10	Faster R-CNN.....	16
2.11	Evaluasi.....	17
<b>BAB III METODOLOGI .....</b>		<b>23</b>
3.1	Pendahuluan .....	23
3.2	Kerangka Kerja .....	23
3.3	Studi Literatur .....	24
3.4	Pengambilan Data .....	24
3.5	Pra-Pengolahan Data .....	24
3.5.1	Seleksi Data.....	25
3.5.2	<i>Ground Truth</i> .....	25
3.5.3	Augmentasi .....	26
3.5.4	Anotasi Data.....	27
3.5.5	Pembagian Data Latih dan Data Uji .....	28
3.6	Segmentasi menggunakan U-Net .....	29
3.7	Segmentasi menggunakan V-Net .....	31
3.8	Proses Segmentasi ke Deteksi .....	32
3.9	Gambar hasil dari proses Segmentasi dan Deteksi.....	32
3.10	<i>Faster R-CNN</i> .....	33
3.10.1	<i>Fast R-CNN</i> .....	33
3.10.2	<i>Region Proposal Network (RPN)</i> .....	34
3.11	Evaluasi.....	34
<b>BAB IV HASIL DAN PEMBAHASAN .....</b>		<b>35</b>
4.1	Pendahuluan .....	35
4.2	Hasil Segmentasi CA pada Pra-kanker serviks menggunakan U-Net .....	35
4.2.1	Hasil Segmentasi CA pada Pra-kanker Serviks Model 1 U-Net .....	36
4.2.2	Hasil Segmentasi CA pada pra-kanker Serviks Model 2 U-Net.....	37
4.2.3	Hasil Segmentasi CA pada pra-kanker Serviks Model 3 U-Net.....	37
4.2.4	Hasil Segmentasi CA pada pra-kanker Serviks Model 4 U-Net.....	38
x		
4.2.5	Hasil Evaluasi Segmentasi CA pada Pra-kanker Serviks U-Net .....	39

4.2.6	Hasil Segmentasi CA ( I ) pada Pra-kanker Serviks Model 1 U-Net.....	40
4.2.7	Hasil Segmentasi CA ( I ) pada Pra-kanker Serviks Model 2 U-Net.....	41
4.2.8	Hasil Segmentasi CA ( I ) pada Pra-kanker Serviks Model 3 U-Net.....	42
4.2.9	Hasil Segmentasi CA ( I ) pada Pra-kanker Serviks Model 4 U-Net.....	43
4.2.10	Hasil Evaluasi Segmentasi CA ( I ) pada Pra-kanker serviks U-Net .....	44
4.2.11	Hasil Segmentasi CA ( II ) pada Pra-kanker Serviks Model 1 U-Net .....	45
4.2.12	Hasil Segmentasi CA ( II ) pada Pra-kanker Serviks Model 2 U-Net .....	46
4.2.13	Hasil Segmentasi CA ( II ) pada Pra-kanker Serviks Model 3 U-Net .....	46
4.2.14	Hasil Segmentasi CA ( II ) pada Pra-kanker Serviks Model 4 U-Net .....	47
4.2.15	Hasil Evaluasi Segmentasi CA ( II ) pada pra-kanker Serviks U-Net .....	48
4.2.16	Hasil Segmentasi Lesi pada Pra-kanker Serviks Model 1 U-Net .....	49
4.2.17	Hasil Segmentasi Lesi pada Pra-kanker Serviks Model 2 U-Net .....	50
4.2.18	Hasil Segmentasi Lesi pada Pra-kanker Serviks Model 3 U-Net .....	51
4.2.19	Hasil Segmentasi Lesi pada Pra-kanker Serviks Model 4 U-Net .....	52
4.2.20	Hasil Evaluasi Segmentasi Lesi pada Pra-kanker Serviks U-Net.....	53
4.2.21	Hasil Segmentasi Lesi ( I ) pada Pra-kanker Serviks Model 1 U-Net .....	53
4.2.22	Hasil Segmentasi Lesi ( I ) pada Pra-kanker Serviks Model 2 U-Net .....	54
4.2.23	Hasil Segmentasi Lesi ( I ) pada Pra-kanker Serviks Model 3 U-Net .....	55
4.2.24	Hasil Segmentasi Lesi ( I ) pada Pra-kanker Serviks Model 4 U-Net .....	56
4.2.25	Hasil evalausi Segmentasi Lesi ( I ) pada pra-kanker Serviks U-Net.....	57
4.2.26	Hasil Segmentasi Lesi ( II ) pada Pra-kanker Serviks Model 1 U-Net .....	58
4.2.27	Hasil Segmentasi Lesi ( II ) pada Pra-kanker Serviks Model 2 U-Net .....	59
4.2.28	Hasil Segmentasi Lesi ( II ) pada Pra-kanker Serviks Model 3 U-Net .....	60
4.2.29	Hasil Segmentasi Lesi ( II ) pada Pra-kanker Serviks Model 4 U-Net .....	61
4.2.30	Hasil Evaluasi Segmentasi Lesi ( II ) pada pra-kanker Serviks U-Net .....	62
4.3	Evaluasi Segmentasi pada Pra-kanker Serviks menggunakan U-Net.....	62
4.4	Gambar Hasil dari Segmentasi U-Net .....	63
4.5	Hasil dari Segmentasi CA Pra-kanker Serviks dengan V-Net .....	64
4.5.1	Hasil Segmentasi CA pada Pra-kanker Serviks Model 1 V-Net .....	64
4.5.2	Hasil Segmentasi CA pada Pra-kanker Serviks Model 2 V-Net .....	65
4.5.3	Hasil Segmentasi CA pada Pra-kanker Serviks Model 3 V-Net .....	66
4.5.4	Hasil Segmentasi CA pada Pra-kanker Serviks Model 4 V-Net .....	67
4.5.5	Hasil Evaluasi Segmentasi CA pada Pra-kanker Serviks V-Net .....	68
4.5.6	Hasil Segmentasi CA ( I ) pada Pra-kanker Serviks Model 1 V-Net.....	69
4.5.7	Hasil Segmentasi CA ( I ) pada Pra-kanker Serviks Model 2 V-Net.....	70
	xi	
4.5.8	Hasil Segmentasi CA ( I ) pada Pra-kanker Serviks Model 3 V-Net.....	70
4.5.9	Hasil Segmentasi CA ( I ) pada Pra-kanker Serviks Model 4 V-Net.....	71

4.5.10	Hasil Evaluasi Segmentasi CA ( I ) pada Pra-kanker Serviks V-Net .....	72
4.5.11	Hasil Segmentasi CA ( II ) pada Pra-kanker Serviks Model 1 V-Net .....	73
4.5.12	Hasil Segmentasi CA ( II ) pada Pra-kanker Serviks Model 2 V-Net .....	74
4.5.13	Hasil Segmentasi CA ( II ) pada Pra-kanker Serviks Model 3 V-Net .....	75
4.5.14	Hasil Segmentasi CA ( II ) pada Pra-kanker Serviks Model 4 V-Net .....	76
4.5.15	Hasil Evaluasi Segmentasi CA ( II ) Pra-kanker Serviks V-Net .....	77
4.5.16	Hasil Segmentasi Lesi pada Pra-kanker Serviks Model 1 V-Net .....	77
4.5.17	Hasil Segmentasi Lesi pada Pra-kanker Serviks Model 2 V-Net .....	78
4.5.18	Hasil Segmentasi Lesi pada Pra-kanker Serviks Model 3 V-Net .....	79
4.5.19	Hasil Segmentasi Lesi pada pra-kanker Serviks Model 4 V-Net .....	80
4.5.20	Hasil Evaluasi Segmentasi Lesi pada Pra-kanker Serviks V-Net.....	81
4.5.21	Hasil Segmentasi Lesi ( I ) pada Pra-kanker Serviks Model 1 V-Net .....	82
4.5.22	Hasil Segmentasi Lesi ( I ) pada Pra-kanker Serviks Model 2 V-Net .....	83
4.5.23	Hasil Segmentasi Lesi ( I ) pada Pra-kanker Serviks Model 3 V-Net .....	84
4.5.24	Hasil Segmentasi Lesi ( I ) pada Pra-kanker Serviks Model 4 V-Net .....	85
4.5.25	Hasil Evaluasi Segmentasi Lesi ( I ) pada Pra-kanker Serviks V-Net .....	86
4.5.26	Hasil Segmentasi Lesi ( II ) pada Pra-kanker Serviks Model 1 V-Net .....	86
4.5.27	Hasil Segmentasi Lesi ( II ) pada Pra-kanker Serviks Model 2 V-Net .....	87
4.5.28	Hasil Segmentasi Lesi ( II ) pada Pra-kanker Serviks Model 3 V-Net .....	88
4.5.29	Hasil Segmentasi Lesi ( II ) pada Pra-kanker Serviks Model 4 V-Net .....	89
4.5.30	Hasil Evalausi Segmentasi Lesi ( II ) pada Pra-kanker Serviks V-Net.....	90
4.6	Evaluasi Segmentasi pada Pra-kanker Serviks menggunakan V-Net.....	91
4.7	Gambar Hasil dari Segmentasi V-Net .....	92
4.8	Hasil dari Deteksi area Lesi Pra-kanker Serviks dengan Faster-RCNN.....	92
4.8.1	Hasil Model 1 menggunakan Faster R-CNN VGG16.....	93
4.8.2	Hasil Model 2 menggunakan Faster R-CNN VGG16.....	95
4.8.3	Hasil Model 3 menggunakan Faster R-CNN VGG16.....	96
4.8.4	Hasil Model 4 menggunakan Faster R-CNN VGG16.....	98
4.8.5	Hasil model 5 menggunakan Faster R-CNN VGG16 .....	99
4.8.6	Hasil model 6 menggunakan Faster R-CNN VGG16 .....	101
4.8.7	Hasil model 7 menggunakan Faster R-CNN VGG16 .....	102
4.8.8	Hasil model 8 menggunakan Faster R-CNN VGG16 .....	104
4.8.9	Hasil model 9 menggunakan Faster R-CNN VGG16 .....	105
4.8.10	Hasil model 10 menggunakan Faster R-CNN VGG16 .....	107
	xii	
4.8.11	Hasil model 11 menggunakan Faster R-CNN VGG16 .....	108
4.8.12	Hasil model 12 menggunakan Faster R-CNN VGG16 .....	110
4.9	Hasil Evaluasi Perbandingan sebuah model Deteksi Faster R-CNN.....	111

4.10	Hasil dari pengujian pada sistem deteksi Faster R-CNN kelas SSK.....	113
<b>BAB V KESIMPULAN.....</b>		<b>114</b>
5.1	Kesimpulan .....	114
5.2	Saran .....	114
<b>DAFTAR PUSTAKA.....</b>		<b>116</b>

## DAFTAR GAMBAR

	<b>Halaman</b>
<b>Gambar 2. 1</b> CA Pra-kanker Serviks.....	9
<b>Gambar 2. 2</b> Sambungan Skuamosa Kolumnar .....	9
<b>Gambar 2. 3</b> Lesi Prakanker Serviks.....	10
<b>Gambar 2. 4</b> Tipe Algoritma Machine Learning [32] .....	12
<b>Gambar 2. 5</b> Kerangka kerja dari Arsitektur U-Net [39].....	14
<b>Gambar 2. 6</b> Kerangka Kerja Arsitektur V-Net [42].....	15
<b>Gambar 2. 7</b> Arsitektur dari Faster R-CNN [45].....	16
<b>Gambar 3. 1</b> Kerangka Kerja .....	23
<b>Gambar 3. 2</b> Pra-pengolahan Data .....	25
<b>Gambar 3. 3</b> Proses Ground Truth CA.....	26
<b>Gambar 3. 4</b> Proses Ground Truth Lesi .....	26
<b>Gambar 3. 5</b> Proses Augmentasi CA .....	26
<b>Gambar 3. 6</b> Proses Augmentasi Lesi .....	27
<b>Gambar 3. 8</b> Arsitektur dari model menggunakan VGG16 [51] .....	33
<b>Gambar 4. 1</b> Model 1 Grafik dari akurasi dan Loss U-Net kelas CA... ..	36
<b>Gambar 4. 2</b> Model 2 Grafik dari akurasi dan Loss Model 2 U-Net kelas CA.....	37
<b>Gambar 4. 3</b> Model 3 Grafik dari akurasi dan Loss U-Net CA.....	38
<b>Gambar 4. 4</b> Model 4 Grafik dari akurasi dan Loss U-Net kelas CA.....	39
<b>Gambar 4. 5</b> Model 1 Grafik dari akurasi dan Loss U-Net kelas CA ( I ).....	41
<b>Gambar 4. 6</b> Model 2 Grafik dari akurasi dan Loss U-Net kelas CA ( I ).....	42
<b>Gambar 4. 7</b> Model 3 Grafik dari akurasi dan Loss U-Net kelas CA (I) .....	43
<b>Gambar 4. 8</b> Model 4 Grafik dari akurasi dan Loss U-Net kelas CA ( I ).....	44
<b>Gambar 4. 9</b> Model 1 Grafik dari akurasi dan Loss U-Net kelas CA (II).....	45
<b>Gambar 4. 10</b> Model 2 Grafik dari akurasi dan Loss U-Net kelas CA ( II ).....	46
<b>Gambar 4. 11</b> Model 3 Grafik dari akurasi dan Loss U-Net kelas CA (II).....	47
<b>Gambar 4. 12</b> Model 4 Grafik dari akurasi dan Loss U-Net kelas CA ( II ).....	48
<b>Gambar 4. 13</b> Model 1 Grafik dari akurasi dan Loss U-Net kelas Lesi.....	50
<b>Gambar 4. 14</b> Model 2 Grafik dari akurasi dan Loss U-Net kelas Lesi.....	51
<b>Gambar 4. 15</b> Model 3 Grafik dari akurasi dan Loss U-Net kelas Lesi.....	52
<b>Gambar 4. 16</b> Model 4 Grafik dari akurasi dan Loss U-Net kelas Lesi.....	53
<b>Gambar 4. 17</b> Model 1 Grafik dari akurasi dan Loss U-Net kelas Lesi ( I ).....	54
<b>Gambar 4. 18</b> Model 2 Grafik dari akurasi dan Loss U-Net kelas Lesi ( I ).....	55

<b>Gambar 4. 19</b> Model 3 Grafik dari akurasi dan Loss U-Net kelas Lesi ( I ).....	56
<b>Gambar 4. 20</b> Model 4 Grafik dari akurasi dan Loss U-Net Lesi ( I ).....	57
<b>Gambar 4. 21</b> Model 1 Grafik dari akurasi dan Loss U-Net kelas Lesi ( II ).....	59
<b>Gambar 4. 22</b> Model 2 Grafik dari akurasi dan Loss U-Net kelas Lesi ( II ).....	60
<b>Gambar 4. 23</b> Model 3 Grafik dari akurasi dan Loss U-Net kelas Lesi ( II ).....	61
<b>Gambar 4. 24</b> Model 4 Grafik dari akurasi dan Loss U-Net kelas Lesi ( II ).....	62
<b>Gambar 4. 25</b> Gambar Hasil Segmentasi U-Net.....	64
<b>Gambar 4. 26</b> Model 1 Grafik dari akurasi dan Loss V-Net kelas CA .....	65
<b>Gambar 4. 27</b> Model 2 Grafik daari Akurasi dan Loss V-Net CA .....	66
<b>Gambar 4. 28</b> Model 3 Grafik dari Akurasi dan Loss V-Net kelas CA .....	67
<b>Gambar 4. 29</b> Model 4 Grafik dari Akurasi dan Loss V-Net kelas CA .....	68
<b>Gambar 4. 30</b> Model 1 Grafik dari Akurasi dan Loss V-Net kelas CA ( I ) .....	69
<b>Gambar 4. 31</b> Model 2 Grafik dari Akurasi dan Loss V-Net kelas CA ( I ) .....	70
<b>Gambar 4. 32</b> Model 4 Grafik dari Akurasi dan Loss V-Net kelas CA ( I ) .....	71
<b>Gambar 4. 33</b> Model 4 Grafik dari Akurasi dan Loss V-Net CA ( I ).....	72
<b>Gambar 4. 34</b> Model 1 Grafik dari Akurasi dan Loss V-Net kelas CA ( II ).....	74
<b>Gambar 4. 35</b> Model 2 Grafik dari Akurasi dan Loss V-Net kelas CA ( II ).....	75
<b>Gambar 4. 36</b> Model 3 Grafik dari Akurasi dan Loss V-Net kelas CA ( II ).....	76
<b>Gambar 4. 37</b> Model 4 Grafik dari Akurasi dan Loss V-Net kelas CA ( II ) .....	77
<b>Gambar 4. 38</b> Model 1 Grafik dari Akurasi dan Loss V-Net kelas Lesi.....	78
<b>Gambar 4. 39</b> Model 2 Grafik dari Aakurasi dan Loss V-Net kelas Lesi .....	79
<b>Gambar 4. 40</b> Model 3 Grafik dari Akurasi dan Loss V-Net kelas Lesi.....	80
<b>Gambar 4. 41</b> Model 4 Grafik dari Akurasi dan Loss V-Net kelas Lesi.....	81
<b>Gambar 4. 42</b> Model 1 Grafik dari Akurasi dan Loss V-Net kelas Lesi ( I ).....	82
<b>Gambar 4. 43</b> Model 2 Grafik dari Akurasi dan Loss V-Net kelas Lesi ( I ).....	83
<b>Gambar 4. 44</b> Model 3 Grafik dari Akurasi dan Loss V-Net kelas Lesi ( I ).....	84
<b>Gambar 4. 45</b> Model 4 Grafik dari Akurasi dan Loss V-Net kelas Lesi ( I ).....	85
<b>Gambar 4. 46</b> Model 1 Grafik dari Akurasi dan Loss V-Net kelas Lesi ( II ).....	87
<b>Gambar 4. 47</b> Model 2 Grafik dari Akurasi dan Loss V-Net kelas Lesi ( II ).....	88
<b>Gambar 4. 48</b> Model 3 Grafik dari Akurasi dan Loss V-Net Lesi ( II ) .....	89
<b>Gambar 4. 49</b> Model 4 Grafik dari Akurasi dan Loss V-Net Lesi ( II ) .....	90
<b>Gambar 4. 50</b> Gambar Hasil Segmentasi V-Net.....	92
<b>Gambar 4. 51</b> Grafik hasil RPN model <i>Loss</i> dari Faster R-CNN SGD MAE 0.00001 .....	94
<b>Gambar 4. 52</b> Grafik hasil Classifier model <i>Loss</i> dari Faster R-CNN SGD MAE 0.00001 .....	94
<b>Gambar 4. 53</b> Grafik hasil RPN model <i>Loss</i> dari Faster R-CNN SGD MSE 0.0001.....	95
<b>Gambar 4. 54</b> Grafik hasil Classifier model <i>Loss</i> dari Faster R-CNN SGD MSE 0.0001 .....	96
<b>Gambar 4. 55</b> Grafik hasil RPN model <i>Loss</i> dari Faster R-CNN SGD MAE 0.001 .....	97

<b>Gambar 4. 56</b>	Grafik hasil Classifier model Loss dari Faster R-CNN SGD MAE 0.001.....	98
<b>Gambar 4. 57</b>	Grafik hasil RPN model Loss dari Faster R-CNN SGD MSE 0.00001.....	98
<b>Gambar 4. 58</b>	Grafik hasil Classifier model Loss dari Faster R-CNN SGD MSE 0.00001 .....	99
<b>Gambar 4. 59</b>	Grafik hasil RPN model Loss dari Faster R-CNN SGD MSE 0.001.....	100
<b>Gambar 4. 60</b>	Grafik hasil Classifier model Loss dari Faster R-CNN SGD MSE 0.001 .....	100
<b>Gambar 4. 61</b>	Grafik hasil RPN model Loss dari Faster R-CNN ADAM MSE 0.001.....	101
<b>Gambar 4. 62</b>	Grafik hasil Classifier model Loss dari Faster R-CNN ADAM MSE 0.001 .....	102
<b>Gambar 4. 63</b>	Grafik hasil RPN model Loss dari Faster R-CNN ADAM MSE 0.0001.....	103
<b>Gambar 4. 64</b>	Grafik hasil Classifier model Loss dari Faster R-CNN ADAM MSE 0.0001 .....	104
<b>Gambar 4. 65</b>	Grafik hasil RPN model Loss dari Faster R-CNN ADAM MSE 0.00001.....	104
<b>Gambar 4. 66</b>	Grafik hasil Classifier model Loss dari Faster R-CNN SGD MSE 0.00001 .....	105
<b>Gambar 4. 67</b>	Grafik hasil RPN model Loss dari Faster R-CNN RMSPROP MAE 0.001.....	106
<b>Gambar 4. 68</b>	Grafik hasil Classifier model Loss dari Faster R-CNN RMSPROP MAE 0.001 .....	106
<b>Gambar 4. 69</b>	Grafik hasil RPN model Loss dari Faster R-CNN RMSPROP MAE 0.0001 .....	107
<b>Gambar 4. 70</b>	Grafik hasil Classifier model Loss dari Faster R-CNN RMSPROP MAE 0.0001 .....	108
<b>Gambar 4. 71</b>	Grafik hasil RPN model Loss dari Faster R-CNN RMSPROP MSE 0.0001.....	109
<b>Gambar 4. 72</b>	Grafik hasil Classifier model Loss dari Faster R-CNN RMSPROP MSE 0.0001 .....	110
<b>Gambar 4. 73</b>	Grafik hasil RPN model Loss dari Faster R-CNN RMSPROP MSE 0.00001 .....	110
<b>Gambar 4. 74</b>	Grafik hasil Classifier model Loss dari Faster R-CNN RMSPROP MSE 0.00001 .....	111

## DAFTAR TABEL

	<b>Halaman</b>
<b>Tabel 3. 1</b> Jumlah Data awal .....	25
<b>Tabel 3. 2</b> Data Augmentasi Lesi .....	27
<b>Tabel 3. 3</b> Data yang digunakan .....	29
<b>Tabel 3. 4</b> Parameter yang digunakan.....	30
<b>Tabel 3. 5</b> Parameter Tuning .....	30
<b>Tabel 3. 6</b> Parameter yang digunakan.....	31
<b>Tabel 3. 7</b> parameter Tuning.....	31
<b>Tabel 4. 1</b> Model Segmentasi U-Net ( I ) dan (II).....	35
<b>Tabel 4. 2</b> Evaluasi hasil model Segmentasi U-Net kelas CA.....	40
<b>Tabel 4. 3</b> Evaluasi hasil Model Segmentasi U-Net kelas CA ( I ) .....	44
<b>Tabel 4. 4</b> Evaluasi hasil Model Segmentasi menggunakan U-Net kelas CA ( II ) .....	49
<b>Tabel 4. 5</b> Evaluasi hasil Model Segmentasi menggunakan U-Net kelas Lesi .....	53
<b>Tabel 4. 6</b> Evaluasi hasil Model Segmentasi Lesi ( I ) menggunakan U-Net .....	58
<b>Tabel 4. 7</b> Evaluasi hasil Segmentasi Lesi (II) menggunakan U-Net.....	62
<b>Tabel 4. 8</b> Evaluasi hasil model Segmentasi menggunakan U-Net.....	63
<b>Tabel 4. 9</b> Hasil evaluasi segmentasi CA menggunakan V-Net.....	68
<b>Tabel 4. 10</b> Evaluasi hasil segmentasi CA ( I ) menggunakan V-Net .....	73
<b>Tabel 4. 11</b> Evaluasi hasil segmentasi CA ( II ) menggunakan V-Net.....	77
<b>Tabel 4. 12</b> Evaluasi hasil segmentasi Lesi menggunakan V-Net.....	81
<b>Tabel 4. 13</b> Evaluasi hasil segmentasi Lesi ( I ) menggunakan V-Net.....	86
<b>Tabel 4. 14</b> Evaluasi hasil segmentasi Lesi ( II ) menggunakan V-Net.....	90
<b>Tabel 4. 15</b> Evaluasi hasil model Segmentasi menggunakan V-Net .....	91
<b>Tabel 4. 16</b> Informasi hyperparameter tuning model deteksi Faster R-CNN .....	92
<b>Tabel 4. 17</b> Hasil Evaluasi Perbandingan model Deteksi Faster R-CNN.....	111

## **DAFTAR LAMPIRAN**

**Lampiran 1.** Form Perbaikan

**Lampiran 2.** Cek Plagiat

# BAB I

## PENDAHULUAN

### 1.1 Latar Belakang

Pra-kanker serviks merupakan awal terjadinya sebuah kanker dan disebut sebagai lesi pra-kanker dan karsinoma serviks (CA) sebelum terbentuknya sel – sel pra kanker yang bernama Lesi, yaitu munculnya sel – sel abnormal pada leher rahim yang merupakan awalan terjadinya pra-kanker serviks, namun apabila tidak diobati maka akan terjadinya kanker serviks yang mana sudah menyebabkan banyaknya kematian disetiap tahunnya. Test skrining, seperti tes Pap Smear yang digunakan untuk melakukan deteksi stadium prakanker yang mampu menghindari terjadinya kanker serviks. Tetapi, tes Pap Smear memiliki beberapa kelemahan yang terjadi yaitu *human error* dan kurang efektifnya preparasi slide, jadi diperkenalkan sistem diagnosis bantuan dari komputer sebagai solusi masalah tersebut. Salah satunya segmentasi citra medis yang menggunakan *U-Net*, *V-Net* dan deteksi objek menggunakan *Faster R-CNN*. [1].

Segmentasi citra adalah memiliki salah satu tugas yang penting sekali dalam pengimplementasian citra medis yang digunakan membantu dokter diagnosis yang lebih akurat atau pendeteksian awal patologi [2]. Segmentasi citra medis membandingkan gambar untuk mengevaluasi kualitas segmentasi dan diberi label setiap piksel untuk mengidentifikasi piksel [3]. Segmentasi merupakan suatu proses yang membagi objek dalam suatu citra yang bertujuan menandai atau mengenali wilayah yang diinginkan berupa kelainan yaitu CA dan Lesi pada pra-kanker serviks.[4]

Sambungan Skuamo kolumnar (SSK) merupakan daerah peralihan mukosa vagina dan mukosa servikalis . SSK itu terlihat seperti garis yang berbeda antara daerah pada kolumnar epitel dan daerah skuamosa[5]. Lesi Pra-kanker atau yang disebut dengan *Cervical Intraepithelial Neoplasia* (CIN) adalah awal dari sebuah kanker yang belum atau tidak menimbulkan keluhan pada sebuah kanker yang belum atau tidak menimbulkan keluhan, dan apabila dibiarkan maka akan berkembang menjadi kanker serviks yang dapat menyebar

ke organ lain [6]. Tingkat pengetahuan yang sangat rendah mengenai Pra-kanker serviks, Sebagian besar tenaga kesehatan menyarankan pengobatan untuk Pra-kanker serviks itu dengan pilihan laser atau menggunakan alat kolposkopi. Untuk membantu dokter diagnosa pasien yang terkena prakanker serviks dengan mendeteksi area Lesi yang terinfeksi dengan melakukan deteksi objek. [7].

Deteksi objek adalah salah satu tugas visi computer yang berperan penting dalam mendeteksi objek visual dari kelas tertentu pada gambar digital, adapun tujuan dari deteksi objek yaitu mengembangkan sebuah model dengan teknik komputasi, yang merupakan salah satu bagian yang paling dasar dalam menyediakan informasi yang dibutuhkan pada pengaplikasian visi computer yaitu pencitraan medis [8]. Dalam melakukan pendeteksian objek dilakukan *framing* pada gambar dengan memisahkan antara ruang yang ingin dideteksi objek dengan memprediksi menggunakan *bounding boxes* dan probabilitas pada kelas yang dideteksi dalam satu evaluasi [9]. Banyak algoritma yang bisa digunakan untuk melakukan proses deteksi tersebut salah satunya metode terbaru yang digunakan dalam melakukan pendeteksian yaitu Convolution Neural Network (CNN) adalah kelas deep, yang telah digunakan untuk menghasilkan sebuah kinerja yang akurat pada *computer vision*, seperti tugas pengklasifikasi dan tugas deteksi citra [10].

Convolution Neural Network (CNN) adalah metode berbasis pembelajaran yang luas dan paling sering digunakan sebagai pemrosesan data visual. CNN yaitu bagian dari jenis neural network yang biasanya sering digunakan untuk data image dan digunakan dalam melakukan deteksi sebuah objek pada image [11]. Pelatihan pada CNN membutuhkan data yang besar dan data tersebut beranotasi, yang mana anotasi tersebut memiliki kualitas tinggi [12]. CNN memberikan cara baru untuk melakukan klasifikasi citra resolusi yang tinggi, dengan menggunakan arsitektur *U-Net* dan *V-Net*. Pada arsitektur *U-Net* memiliki rentang skala yang berbeda dalam menghasilkan klasifikasinya yaitu per-piksel dari citra input [13]. *U-Net* adalah salah satu jaringan yang sering dalam melakukan segmentasi citra medis dan paling populer, dan *U-Net* menggunakan jaringan dari lapisan konvolusi dalam melakukan proses

segmentasi *semantic*. Arsitektur jaringannya mengekstrak fitur yang memiliki *encoder* dan *decoder* membangun sebuah peta segmentasi dari sebuah fitur yang telah dikodekan dan konvolusi menghubungkan keduanya [14]. V-Net memiliki kegunaan sebagai melakukan perbaikan pada fitur dengan tujuan untuk mendapatkan hasil akhir pada saat melakukan segmentasi [15].

*Faster R-CNN* adalah metode yang sangat luar biasa yang disebut sebagai algoritma deteksi dan sering digunakan dalam melakukan deteksi objek yang dihasilkan dari bounding box dalam menentukan objek pada gambar yang dideteksi. *Faster R-CNN* yaitu gabungan dari keduanya, antara metode *fast R-CNN* dengan *Region Proposal network (RPN)* yang menunjukkan hasil kinerja yang sangat bagus untuk deteksi objek [16].

## 1.2 Rumusan masalah dan Tujuan

### 1.2.1 Rumusan Masalah

Berikut batasan masalah pada penelitian untuk tugas akhir ini, adalah sebagai berikut :

1. Bagaimana melakukan segmentasi citra CA dan area Lesi terinfeksi pada kasus Pra-kanker Serviks yang menggunakan *U-Net* dan *V-Net*?
2. Bagaimana mendapatkan hasil dalam melakukan Segmentasi CA dan area Lesi terinfeksi pada kasus Pra-kanker Serviks yang menggunakan *U-Net* dan *V-Net* ?
3. Bagaimana melakukan deteksi area Lesi terinfeksi yang menggunakan kelas SSK dengan *Faster-RCNN* ?
4. Bagaimana menganalisa model terbaik untuk segmentasi CA dan Lesi, serta deteksi area Lesi terinfeksi pada Pra-kanker Serviks kelas SSK?

### 1.2.2 Tujuan

Adapun dalam penelitian ini memiliki tujuan pada Tugas Akhir , yaitu:

1. Membangun suatu proses Segmentasi Citra Pra-kanker Serviks menggunakan *U-Net dan V-Net*
2. Mendapatkan hasil dari Segmentasi Citra Pra-kanker Serviks yang menggunakan *U-Net dan V-Net*
3. Dapat mendeteksi area Lesi terinfeksi yang menggunakan kelas SSK dengan *Faster-RCNN*
4. Mengukur kinerja evaluasi Segmentasi CA dan Lesi terinfeksi pada kasus Pra-kanker Serviks, yang akan diukur menggunakan *Metric Evaluation* yang terdiri dari *Pixel Accuracy, IoU (Intersection Over Union), Mean Accuracy, FPR (False Positive Rate), Precision, Recall dan F1 Score* dan deteksi SSK menggunakan *Mean Average Precesion (mAP)*

### **1.3 Manfaat dan Batasan Masalah**

#### **1.3.1 Manfaat**

Adapun manfaat dari tugas akhir ini adalah :

1. Dapat membantu para tenaga medis untuk segmentasi CA dan Lesi serta mendeteksi bagian area Lesi teinfeksi kelas SSK pada kasus Pra-kanker Serviks
2. Dapat dijadikan sebagai alat bantu untuk dokter dalam mengambil keputusan diagnosis area Lesi terinfeksi
3. Sebagai referensi belajar untuk semua akademisi dan bagi orang orang yang sedang melakukan penelitian dibidang citra. Penelitian tentang segmentasi dan deteksi area Lesi terinfeksi khususnya pada kasus Pra-kanker Serviks

#### **1.3.2 Batasan Masalah**

Berikut Batasan masalah dari tugas akhir, ini adalah sebagai berikut :

1. Penelitian ini menggunakan citra gambar Pra-kanker Serviks pada area Lesi teinfeksi, CA dan SSK

2. Dataset yang digunakan yaitu dataset Pra-kanker Serviks kelas normal dan abnormal.
3. Segmentasi dan deteksi dilakukan terhadap data Pra-kanker Serviks.
4. Penelitian ini sebatas simulasi program yang menggunakan Bahasa pemrograman *python*.

#### **1.4 Metodologi Penulisan**

Pada peneletian Tugas Akhir ini, untuk metodologi yang digunakan yaitu :

##### **1.4.1 Metode Studi Pustaka dan Literatur**

Pada bagian metode ini, penulis melakukan pengumpulan dan pencarian referensi atau sumber berupa literatur yang ada pada jurnal, paper, dibuku dan diinternet dalam melakukan segmentasi *U-Net* Pra-kanker Serviks normal dan abnormal dan deteksi 1 objek Pra-kanker Serviks abnormal pada area Lesi terinfeksi menggunakan kelas SSK arsitektur *Faster region Based Convolutional Neural Network (Faster R-CNN)*.

##### **1.4.2 Metode Konsultasi**

Pada bagian metode ini, penulis melakukan metode konsultasi yang dilakukan secara tidak langsung dan langsung kepada semua bidang yang berkaitan dengan ilmu pengetahuan serta wawasan dalam hal mengatasi suatu permasalahan pada penulisan Tugas Akhir ini, yang berkaitan mengenai segmentasi *U-Net* Pra-kanker Serviks normal dan abnormal dan deteksi 1 objek Pra-kanker Serviks abnormal pada Lesi terinfeksi menggunakan kelas SSK dengan arsitektur *Faster Region Based Convolution Neural Network (Faster R-CNN)*.

##### **1.4.3 Metode Pembuatan Model**

Pada bagian metode ini, penulis melakukan suatu perancangan terlebih dahulu dalam melakukan sebuah pembuatan modelan yang menggunakan program dengan bahasa pemrograman *python*.

#### **1.4.4 Metode Pengujian dan Validasi**

Pada bagian metode ini, penulis melakukan percobaan dan validasi terhadap system yang telah dibuat agar bisa dilihat kinerja pada system, apakah mendapatkan hasil nilai yang bagus dan baik atau tidak.

#### **1.4.5 Metode hasil dan Analisa**

Pada metode ini, setelah penulis melakukan pengujian dan validasi maka akan dilakukan analisa pada seluruh kelebihan dan kekurangannya, agar dapat digunakan sebagai bahan referensi atau sumber yang baik dalam melakukan penelitian yang dilakukan berikutnya.

#### **1.4.6 Metode Penarikan Kesimpulan dan Saran**

Pada bagian metode ini, penulis akan mengambil kesimpulan serta saran pada sebuah hasil dan Analisa yang telah didapatkan untuk penelitian yang dilakukan berikutnya. Metode ini adalah tahapan terakhir pada metodologi penelitian.

### **1.5 Sistematika Penulisan**

Untuk mempermudah dalam melakukan penyusunan penulisan Tugas Akhir dan membuat sebuah isi pada setiap bab pada Tugas Akhir ini agar lebih mudah dimenegrti dan jelas, maka dibuat sistematika penulisan yaitu:

#### **BAB I – PENDAHULUAN**

Pada bagian bab ini akan membahas sebuah Latar Belakang, Rumusan masalah, Tujuan, manfaat dan Batasan Masalah, Metodologi Penelitian, dan membahas Sistematika Penulisan.

#### **BAB II – TINJAUAN PUSTAKA**

Pada bagian bab ini akan membahas tentang penjelasan berkaitan dengan pembahsan dari penelitian ini, yaitu dasar teori, terdapat literatur dari penelitian sebelumnya mengenai segmentasi dan deteksi yang berkaitan dengan citra medis pada Pra-kanker Serviks, *Machine Learning*, *Deep Learning* dan Arsitektur model yang akan digunakan.

### **BAB III – METODOLOGI PENELITIAN**

Pada bagian bab ini akan membahas sebuah tahapan – tahapan penelitian yang akan dilakukan oleh peneliti, yang mana dimulai dari kerangka kerja, studi literatur, pengambilan data, persiapan Pra-Pengolahan data serta bagaimana sebuah metode dalam mempelajari suatu data yang digunakan.

### **BAB IV – HASIL DAN PEMBAHASAN**

Pada bagian bab ini akan membahas hasil serta pembahasan dari kinerja segmentasi Pra-kanker Serviks normal dan abnormal yang menggunakan *U-Net* dan deteksi 1 objek Pra-kanker Serviks abnormal pada Lesi terinfeksi menggunakan *Faster R-CNN*.

### **BAB V – KESIMPULAN DAN SARAN**

Pada bab ini akan membahas sebuah kesimpulan dan saran yang didapat dari suatu hasil dan pembahsan yang sudah dilakukan mengenai segmentasi Pra-kanker Serviks normal dan abnormal yang menggunakan *U-Net* dan deteksi objek Pra-kanker Serviks abnormal pada Lesi terinfeksi menggunakan *Faster R-CNN*, yang mana diharapkan berguna untuk penelitian yang dilakukan selanjutnya.

## DAFTAR PUSTAKA

- [1] S. N. Sulaiman, N. A. Mat-Isa, N. H. Othman, and F. Ahmad, "Improvement of features extraction process and classification of Cervical cancer for the NeuralPap system," *Procedia Comput. Sci.*, vol. 60, no. 1, pp. 750–759, 2015, doi: 10.1016/j.procs.2015.08.228.
- [2] S. Egmentation, D. L. Pham, C. Xu, and J. L. Prince, "C m m i s," 2000.
- [3] A. A. Taha and A. Hanbury, "Metrics for evaluating 3D medical image segmentation: Analysis, selection, and tool," *BMC Med. Imaging*, vol. 15, no. 1, 2015, doi: 10.1186/s12880-015-0068-x.
- [4] N. Sharma *et al.*, "Automated medical image segmentation techniques," *J. Med. Phys.*, vol. 35, no. 1, pp. 3–14, 2010, doi: 10.4103/0971-6203.58777.
- [5] U. Hayati, U. Salmah, and R. M. Thaha, "Risk Factors of Family History, Use of Contraception Hormon and Smoking on the Event of Cervical Cancer in Bima Regional General Hospital," vol. 4413, pp. 169–172, 2019, doi: 10.36349/easmb.2019.v02i06.007.
- [6] M. Arbyn *et al.*, "Incomplete excision of cervical precancer as a predictor of treatment failure: a systematic review and meta-analysis," *Lancet Oncol.*, vol. 18, no. 12, pp. 1665–1679, 2017, doi: 10.1016/S1470-2045(17)30700-3.
- [7] F. Tarwireyi, Z. M. Chirenje, and S. Rusakaniko, "Cancer of the cervix: knowledge, beliefs and screening behaviours of health workers in Mudzi District in Mashonaland East Province, Zimbabwe.," *Cent. Afr. J. Med.*, vol. 49, no. 7–8, pp. 83–86, 2003.
- [8] Z. Zou, Z. Shi, Y. Guo, and J. Ye, "Object Detection in 20 Years: A Survey," pp. 1–39, 2019, [Online]. Available: <http://arxiv.org/abs/1905.05055>.
- [9] G. Plastiras, C. Kyrkou, and T. Theodoridis, "Efficient convnet-based object detection for unmanned aerial vehicles by selective tile processing," *ACM Int. Conf. Proceeding Ser.*, 2018, doi: 10.1145/3243394.3243692.

- [10] R. L. Galvez, A. A. Bandala, E. P. Dadios, R. R. P. Vicerra, and J. M. Z. Maningo, "Object Detection Using Convolutional Neural Networks," *IEEE Reg. 10 Annu. Int. Conf. Proceedings/TENCON*, vol. 2018-October, no. October, pp. 2023–2027, 2019, doi: 10.1109/TENCON.2018.8650517.
- [11] S. K. Roy, G. Krishna, S. R. Dubey, and B. B. Chaudhuri, "HybridSN: Exploring 3-D-2-D CNN Feature Hierarchy for Hyperspectral Image Classification," *IEEE Geosci. Remote Sens. Lett.*, vol. 17, no. 2, pp. 277–281, 2020, doi: 10.1109/LGRS.2019.2918719.
- [12] F. Radenovic, G. Tolias, and O. Chum, "Fine-Tuning CNN Image Retrieval with No Human Annotation," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 41, no. 7, pp. 1655–1668, 2019, doi: 10.1109/TPAMI.2018.2846566.
- [13] N. Flood, F. Watson, and L. Collett, "Using a U-net convolutional neural network to map woody vegetation extent from high resolution satellite imagery across Queensland, Australia," *Int. J. Appl. Earth Obs. Geoinf.*, vol. 82, no. February, p. 101897, 2019, doi: 10.1016/j.jag.2019.101897.
- [14] N. Ibtehaz and M. S. Rahman, "MultiResUNet: Rethinking the U-Net architecture for multimodal biomedical image segmentation," *Neural Networks*, vol. 121, pp. 74–87, 2020, doi: 10.1016/j.neunet.2019.08.025.
- [15] T. Lei, W. Zhou, Y. Zhang, R. Wang, H. Meng, and A. K. Nandi, "LIGHTWEIGHT V-NET FOR LIVER SEGMENTATION School of Electronic Informataion and Artificial Intelligence , Shaanxi University of Science and Technology , Department of Electronic and Computer Engineering , Brunel University London , Uxbridge , Middlesex , UB," *ICASSP 2020 - 2020 IEEE Int. Conf. Acoust. Speech Signal Process.*, pp. 1379–1383, 2020.
- [16] L. Zhang, L. Lin, X. Liang, and K. He, "Is faster R-CNN doing well for pedestrian detection?," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 9906 LNCS, pp. 443–457, 2016, doi: 10.1007/978-3-319-46475-6\_28.
- [17] Y. N. Mirabal, S. K. Chang, E. N. Atkinson, A. Malpica, M. Follen, and R.

- Richards-Kortum, “Reflectance spectroscopy for in vivo detection of cervical precancer,” *J. Biomed. Opt.*, vol. 7, no. 4, p. 587, 2002, doi: 10.1117/1.1502675.
- [18] universitas negeri Sugiyono, “Studi pustaka,” *J. Chem. Inf. Model.*, vol. 53, no. 9, pp. 1689–1699, 2019.
- [19] H. C. Kitchener *et al.*, “A cluster randomised trial of strategies to increase cervical screening uptake at first invitation (STRATEGIC),” *Health Technol. Assess. (Rockv)*, vol. 20, no. 68, 2016, doi: 10.3310/hta20680.
- [20] G. Haider, Z. Parveen, F. Anjum, and A. Munir, “Pap smear, an important screening tool to detect precancerous stage of carcinoma of cervix.,” *J. Ayub Med. Coll. Abbottabad*, vol. 25, no. 1–2, pp. 26–27, 2013.
- [21] Y. Maru *et al.*, “Establishment and molecular phenotyping of organoids from the squamocolumnar junction region of the uterine cervix,” *Cancers (Basel)*, vol. 12, no. 3, pp. 1–15, 2020, doi: 10.3390/cancers12030694.
- [22] J. Mirkovic *et al.*, “junction,” vol. 236, no. 3, pp. 265–271, 2016, doi: 10.1002/path.4533.Carcinogenic.
- [23] E. Muiitta, T. Were, A. K. Nyamache, and N. Muhoho, “Atypical cervical cytomorphologic predictors: A descriptive study of pre-cervical cancer patients of low education in kenya,” *Pan Afr. Med. J.*, vol. 33, pp. 1–12, 2019, doi: 10.11604/pamj.2019.33.124.15753.
- [24] L. Hu *et al.*, “An Observational Study of Deep Learning and Automated Evaluation of Cervical Images for Cancer Screening,” *J. Natl. Cancer Inst.*, vol. 111, no. 9, pp. 923–932, 2019, doi: 10.1093/jnci/djy225.
- [25] A. C and Savithri, “Computing the Efficiency of Image Segmentation Techniques in Fmri Analysis,” *Int. J. Res. -GRANTHAALAYAH*, vol. 5, no. 3, pp. 223–237, 2017, doi: 10.29121/granthaalayah.v5.i3.2017.1772.
- [26] D. Colvin, “Use of the cervicoscope in general practice,” *Br. J. Gen. Pract.*, vol. 47, no. 414, pp. 43–44, 1997.

- [27] O. N. Shpakov and G. V. Bogomolov, "Technogenic activity of man and local sources of environmental pollution," *Stud. Environ. Sci.*, vol. 17, no. C, pp. 329–332, 1981, doi: 10.1016/S0166-1116(08)71924-1.
- [28] K. Bhargavi and S. Jyothi, "A Survey on Threshold Based Segmentation Technique in Image Processing," *Int. J. Innov. Res. Dev.*, vol. 3, no. 12, pp. 234–39, 2014, [Online]. Available: [https://www.researchgate.net/profile/Singaraju\\_Jyothi2/publication/309209325\\_A\\_Survey\\_on\\_Threshold\\_Based\\_Segmentation\\_Technique\\_in\\_Image\\_Processing/links/5805bb6f08aee314f68e2879/A-Survey-on-Threshold-Based-Segmentation-Technique-in-Image-Processing.pdf](https://www.researchgate.net/profile/Singaraju_Jyothi2/publication/309209325_A_Survey_on_Threshold_Based_Segmentation_Technique_in_Image_Processing/links/5805bb6f08aee314f68e2879/A-Survey-on-Threshold-Based-Segmentation-Technique-in-Image-Processing.pdf).
- [29] A. Vyas, S. Yu, and J. Paik, *Fundamentals of digital image processing*. 2018.
- [30] M. Grundland and N. A. Dodgson, "Decolorize: Fast, contrast enhancing, color to grayscale conversion," *Pattern Recognit.*, vol. 40, no. 11, pp. 2891–2896, 2007, doi: 10.1016/j.patcog.2006.11.003.
- [31] D. H. Kim, J. Bin Park, J. H. Shin, and J. D. Kim, "Design and implementation of object tracking system based on LoRa," *Int. Conf. Inf. Netw.*, no. November, pp. 463–467, 2017, doi: 10.1109/ICOIN.2017.7899535.
- [32] W. William, A. H. Basaza-Ejiri, J. Obungoloch, and A. Ware, "A review of applications of image analysis and machine learning techniques in automated diagnosis and classification of cervical cancer from pap-smear images," *2018 IST-Africa Week Conf. IST-Africa 2018*, 2018.
- [33] R. Justo-Silva, A. Ferreira, and G. Flintsch, "Review on machine learning techniques for developing pavement performance prediction models," *Sustain.*, vol. 13, no. 9, pp. 1–27, 2021, doi: 10.3390/su13095248.
- [34] M. Fatima and M. Pasha, "Survey of Machine Learning Algorithms for Disease Diagnostic," *J. Intell. Learn. Syst. Appl.*, vol. 09, no. 01, pp. 1–16, 2017, doi: 10.4236/jilsa.2017.91001.
- [35] X. Hao, G. Zhang, and S. Ma, "Deep Learning," *Int. J. Semant. Comput.*,

- vol. 10, no. 3, pp. 417–439, 2016, doi: 10.1142/S1793351X16500045.
- [36] A. Kamilaris and F. X. Prenafeta-Boldú, “Deep learning in agriculture: A survey,” *Comput. Electron. Agric.*, vol. 147, pp. 70–90, 2018, doi: 10.1016/j.compag.2018.02.016.
- [37] J. Wang, Y. Ma, L. Zhang, R. X. Gao, and D. Wu, “Deep learning for smart manufacturing: Methods and applications,” *J. Manuf. Syst.*, vol. 48, pp. 144–156, 2018, doi: 10.1016/j.jmsy.2018.01.003.
- [38] D. Suryani, P. Doetsch, and H. Ney, “On the benefits of convolutional neural network combinations in offline handwriting recognition,” *Proc. Int. Conf. Front. Handwrit. Recognition, ICFHR*, vol. 0, pp. 193–198, 2016, doi: 10.1109/ICFHR.2016.0046.
- [39] M. Z. Alom, C. Yakopcic, M. Hasan, T. M. Taha, and V. K. Asari, “Recurrent residual U-Net for medical image segmentation,” *J. Med. Imaging*, vol. 6, no. 01, p. 1, 2019, doi: 10.1117/1.jmi.6.1.014006.
- [40] Z. Liu *et al.*, “Segmentation of organs-at-risk in cervical cancer CT images with a convolutional neural network,” *Phys. Medica*, vol. 69, no. April 2019, pp. 184–191, 2020, doi: 10.1016/j.ejmp.2019.12.008.
- [41] X. Y. Zhou and G. Z. Yang, “Normalization in training U-Net for 2-D biomedical semantic segmentation,” *IEEE Robot. Autom. Lett.*, vol. 4, no. 2, pp. 1792–1799, 2019, doi: 10.1109/LRA.2019.2896518.
- [42] F. Milletari, N. Navab, and S. A. Ahmadi, “V-Net: Fully convolutional neural networks for volumetric medical image segmentation,” *Proc. - 2016 4th Int. Conf. 3D Vision, 3DV 2016*, pp. 565–571, 2016, doi: 10.1109/3DV.2016.79.
- [43] G. Pre-processor, E. C. Chui, L. C. Lau, K. Kwok, X. Ye, and L. Hung, “Clinics in Surgery Improving the Performance of V-Net Architecture for Volumetric Medical Image Segmentation by Implementing,” vol. 6, pp. 1–5, 2021.
- [44] F. R-cnn, “International Journal of Medical Informatics Multi-Class brain

- normality and abnormality diagnosis using modified Faster R-CNN,” vol. 155, no. September, 2021, doi: 10.1016/j.ijmedinf.2021.104576.
- [45] Z. Deng, H. Sun, S. Zhou, J. Zhao, L. Lei, and H. Zou, “Multi-scale object detection in remote sensing imagery with convolutional neural networks,” *ISPRS J. Photogramm. Remote Sens.*, vol. 145, no. June, pp. 3–22, 2018, doi: 10.1016/j.isprsjprs.2018.04.003.
- [46] P. Prentašić *et al.*, “Segmentation of the foveal microvasculature using deep learning networks,” *J. Biomed. Opt.*, vol. 21, no. 7, p. 075008, 2016, doi: 10.1117/1.jbo.21.7.075008.
- [47] R. Castello, S. Roquette, M. Esguerra, A. Guerra, and J. L. Scartezzini, “Deep learning in the built environment: Automatic detection of rooftop solar panels using Convolutional Neural Networks,” *J. Phys. Conf. Ser.*, vol. 1343, no. 1, 2019, doi: 10.1088/1742-6596/1343/1/012034.
- [48] G. Han *et al.*, “Improved U-Net based insulator image segmentation method based on attention mechanism,” *Energy Reports*, vol. 7, pp. 210–217, 2021, doi: 10.1016/j.egy.2021.10.037.
- [49] P. Barmpoutis, K. Dimitropoulos, K. Kaza, and N. Grammalidis, “Fire Detection from Images Using Faster R-CNN and Multidimensional Texture Analysis,” *ICASSP, IEEE Int. Conf. Acoust. Speech Signal Process. - Proc.*, vol. 2019-May, no. February, pp. 8301–8305, 2019, doi: 10.1109/ICASSP.2019.8682647.
- [50] H. Zhang and X. Hong, *Recent progresses on object detection: a brief review*, vol. 78, no. 19. Multimedia Tools and Applications, 2019.
- [51] S. Tammina, “Transfer learning using VGG-16 with Deep Convolutional Neural Network for Classifying Images,” *Int. J. Sci. Res. Publ.*, vol. 9, no. 10, p. p9420, 2019, doi: 10.29322/ijsrp.9.10.2019.p9420.
- [52] N. S. Keskar and R. Socher, “Improving Generalization Performance by Switching from Adam to SGD,” no. 1, 2017, [Online]. Available: <http://arxiv.org/abs/1712.07628>.

- [53] J. Yang and G. Yang, “Modified convolutional neural network based on dropout and the stochastic gradient descent optimizer,” *Algorithms*, vol. 11, no. 3, pp. 1–15, 2018, doi: 10.3390/a11030028.