

**SEGMENTASI SEMANTIK *MULTICLASS* PADA
CITRA PRA-KANKER SERVIKS MENGGUNAKAN
*DEEP LEARNING***

SKRIPSI

**Diajukan Untuk Melengkapi Salah Satu Syarat
Memperoleh Gelar Sarjana Komputer**



OLEH :

**MUHAMMAD REZKY HAMESI AKHYAR
09011281924038**

**JURUSAN SISTEM KOMPUTER
FAKULTAS ILMU KOMPUTER
UNIVERSITAS SRIWIJAYA
2023**

LEMBAR PENGESAHAN

SEGMENTASI SEMANTIK MULTICLASS PADA CITRA PRA-KANKER SERVIKS MENGGUNAKAN DEEP LEARNING

SKRIPSI

Diajukan Untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sistem Komputer

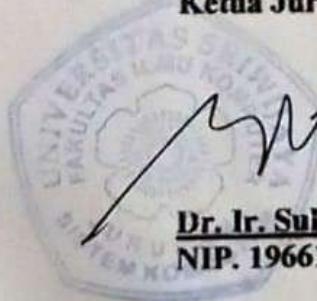
Oleh :

MUHAMMAD REZKY HAMESI AKHYAR
09011281924038

Palembang, 27 Juli 2023

Mengetahui,

Ketua Jurusan Sistem Komputer



Dr. Ir. Sukemi, M.T.
NIP. 196612032006041001

Pembimbing Tugas Akhir

Prof. Dr. Ir. Siti Nurmaini, M.T., Ph.D
NIP. 196908021994012001

HALAMAN PERSETUJUAN

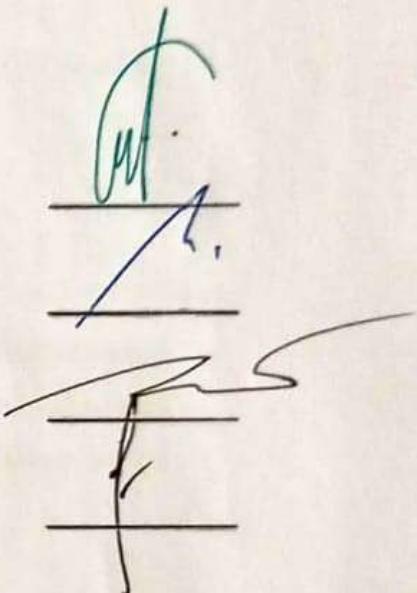
Telah diuji dan lulus pada :

Hari : Kamis

Tanggal : 6 Juli 2023

Tim Penguji :

1. Ketua : Dr. Ahmad Zarkasi, M.T.
2. Sekretaris : Adi Hermansyah, M.T.
3. Penguji : Rossi Passarella, M.Eng
4. Pembimbing : Prof. Ir. Siti Nurmaini, M.T., Ph.D.



Mengetahui, 31/7/23

Ketua Jurusan Sistem Komputer



Dr. Ir. Sukemi, M.T.

NIP. 196612032006041001

HALAMAN PERNYATAAN

Yang bertanda tangan di bawah ini :

Nama : Muhammad Rezky Hamesi Akhyar

NIM : 09011281924038

Judul : Segmentasi Semantik *Multiclass* Pada Citra Pra-Kanker Serviks
Menggunakan *Deep Learning*

Hasil Pengecekan Software Turnitin : 1%

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 tanpa paksaan dari siapapun.



Palembang, 31 Juli 2023



Muhammad Rezky Hamesi Akhyar

NIM. 09011281924038

KATA PENGANTAR

Alhamdulillahirabbil ‘alamiin. Segala puji dan syukur penulis panjatkan kepada Allah Subhana Wata’ala atas segala rahmat, nikmat serta karunia-Nya, sehingga penulis dapat menyelesaikan tugas akhir dengan judul “**Segmentasi Semantik Multiclass pada Citra Pra-Kanker Serviks Menggunakan Deep Learning**”.

Selama menyusun tugas akhir ini, penulis banyak mendapatkan bantuan, bimbingan dan dukungan dari berbagai pihak baik secara langsung maupun secara tidak langsung sehingga penulis mampu menyelesaikan tugas akhir ini secara tepat waktu. Pada kesempatan ini, penulis ingin mengucapkan rasa syukur kepada Allah SWT dan menyampaikan terimakasih kepada semua pihak yang terlibat antara lain:

1. Kedua orang tua tercinta, ayah dan bunda yang selalu mendoakan dan memberikan nasihat dengan penuh kasih dan sayang.
2. Saudara dan saudari kandung yang selalu memberikan semangat serta dukungan.
3. Bapak Dr. Ir. H. Sukemi, M.T. selaku Ketua Jurusan Sistem Komputer Fakultas Ilmu Komputer Universitas Sriwijaya.
4. Prof. Dr. Ir. Siti Nurmaini, M.T. selaku Dosen Pembimbing Tugas Akhir yang telah membantu membimbing penulis dalam menyelesaikan Tugas Akhir.
5. Pak Naufal Rachmatullah selaku asisten Laboratorium Intelligent Systems Research Group (IsysRG) yang telah memberikan dukungan serta membimbing penulis dalam penulisan Tugas Akhir.
6. Terima kasih kepada Intelligent System Research Group (ISysRG) atas bantuan infrastuktur dalam menyelesaikan Tugas Akhir.
7. Teman – teman di Laboratorium *Intelligent Systems Research Group* (IsysRG) dan teman – teman jurusan sistem komputer kelas A.
8. Salwa Ayu Rafika yang selalu memberikan semangat dan dukungan.

Dalam penyusunan tugas akhir ini, penulis menyadari bahwa masih banyak terdapat kekurangan. Untuk itu, penulis mengharapkan masukan berupa kritik dan saran yang membangun demi kesempuraan di masa depan. Akhir kata penulis berharap, semoga tugas akhir ini dapat menjadi amal ibadah dan bermanfaat bagi orang lain.

Palembang, 31 Juli 2023

Penulis,



Muhammad Rezky Hamesi Akhyar
NIM. 09011281924038

Segmentasi Semantik *Multiclass* Pada Citra Pra-Kanker Serviks
Menggunakan *Deep Learning*

Muhammad Rezky Hamesi Akhyar (09011281924038)

Jurusan Sistem Komputer, Fakultas Ilmu Komputer, Universitas Sriwijaya

Email : muhammadrezkyhamesi@gmail.com

ABSTRAK

Teknologi *Artificial Intelligence* (AI) dalam bidang *Computer Vision* (CV) dapat dimanfaatkan untuk mendeteksi kanker serviks menggunakan salah satu pendekatan yaitu Segmentasi Citra. Seiring dengan kemajuan teknologi, proses segmentasi citra dapat diimplementasikan dengan model *Deep Learning* (DL). Penelitian ini menggunakan arsitektur *U-Net* dengan *backbone* untuk proses segmentasi semantik citra pra-kanker serviks. Terdapat 12 *Backbone* yang dikombinasikan dengan arsitektur *U-Net* yaitu *Vgg16*, *Vgg19*, *ResNet50*, *ResNext50*, *EfficientNetb7*, *InceptionResNetv2*, *DenseNet201*, *Inceptionv3*, *Mobilenetv2*, *Se-ResNet50*, *SE-ResNext50*, dan *SE-Net154*. Performa terbaik dicapai oleh model *U-Net* dengan menggunakan backbone *SENet154*. Hasil evaluasi model U-Net dengan backbone *SENet154* pada metrik evaluasi *Pixel Accuracy*, *Intersection Over Union* (IoU) dan *Dice Coefficient* masing-masing sebesar 81.82%, 71.69% dan 82.29%.

Keywords : Segmentasi Semantik, *Deep Learning*, *Artificial Intelligence*, *Computer Vision*, Citra Pra-Kanker Serviks

Multiclass Semantic Segmentation in Pre-Cancer Cervical Images Using Deep Learning

Muhammad Rezky Hamesi Akhyar (09011281924038)

Computer Engineering Department, Computer Science Faculty, Sriwijaya University

Email : muhammadrezkyhamesi@gmail.com

ABSTRACT

Artificial Intelligence (AI) technology in the field of Computer Vision (CV) can be utilized to detect cervical cancer using the Image Segmentation approach. With the advancement of technology, image segmentation processes can be implemented using Deep Learning (DL) models. This research utilizes the U-Net architecture with backbones for pre-cervical cancer semantic image segmentation. There are 12 backbones combined with the U-Net architecture: Vgg16, Vgg19, ResNet50, ResNext50, EfficientNetb7, InceptionResNetv2, DenseNet201, Inceptionv3, Mobilenetv2, Se-ResNet50, SE-ResNext50, and SENet154. The best performance is achieved by the U-Net model using the SENet154 backbone. The evaluation results of the U-Net model with the SENet154 backbone on the metrics of Pixel Accuracy, Intersection Over Union (IoU), and Dice Coefficient are 81.82%, 71.69%, and 82.29%, respectively.

Keywords : Semantic Segmentation, Deep Learning, Artificial Intelligence, Computer Vision, Cervical Pre-Cancer Image

DAFTAR ISI

LEMBAR PENGESAHAN	ii
HALAMAN PERSETUJUAN	iii
HALAMAN PERNYATAAN	iv
KATA PENGANTAR.....	v
ABSTRAK	vii
ABSTRACT	viii
DAFTAR ISI.....	ix
DAFTAR GAMBAR.....	xii
DAFTAR TABEL	xiii
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.3 Tujuan.....	3
1.4 Manfaat.....	3
1.5 Rumusan Masalah	3
1.6 Batasan Masalah.....	3
1.7 Sistematika Penelitian	4
BAB II TINJAUAN PUSTAKA	6
2.1 <i>Artificial Intelligence</i>	6
2.2 <i>Computer Vision</i>	7
2.3 Segmentasi	7
2.4 Segmentasi Semantik	9
2.5 Segmentasi <i>Instance</i>	10
2.6 Segmentasi <i>Panoptic</i>	11
2.7 <i>Deep Learning</i>	12
2.8 <i>Convolutional Neural Network</i>	13
2.9 U-Net	14
2.10 Citra Pra-Kanker Serviks.....	15
2.11 <i>Backbone Network</i>	15
2.12 Pengukuran Kinerja	16
2.12.1 <i>Intersection Over Union</i>	16
2.12.2 <i>Pixel Accuracy</i>	16

2.12.3	<i>Dice Coefficient</i>	17
2.12.4	<i>Mean Average Precision</i>	17
BAB III METODOLOGI PENELITIAN	18
3.1	Pendahuluan	18
3.2	Kerangka Kerja Penelitian.....	18
3.3	Persiapan Data.....	20
3.4	Pra-Pengolahan Data	20
3.5	Pembuatan Ground Truth	21
3.5.1	Anotasi Objek	21
3.5.2	Pembuatan Label.....	23
3.5.3	Pembuatan File Ground Truth	24
3.6	Pembuatan Dataset	25
3.7	<i>K-Fold Cross Validation</i>	26
3.8	Pelatihan Model.....	26
3.9	Hyperparameter Tuning	27
3.10	Evaluasi Model	27
BAB IV HASIL DAN PEMBAHASAN	28
4.1	Pendahuluan	28
4.2	Hasil Segmentasi Semantik	28
4.2.1	Model U-Net-VGG16	28
4.2.2	Model U-Net - VGG19	31
4.2.3	Model U-Net - ResNet50	34
4.2.4	Model U-Net - ResNext50	37
4.2.5	Model U-Net - EfficientNetb7	40
4.2.6	Model U-Net - InceptionResNetv2	43
4.2.7	Model U-Net - DenseNet201	46
4.2.8	Model U-Net - Inceptionv3.....	49
4.2.9	Model U-Net - MobileNetv2	52
4.2.10	Model U-Net - SEResNet50	55
4.2.11	Model U-Net - SEResNext50	58
4.2.12	Model U-Net - SENet154	61
4.3	Rangkuman Evaluasi dan Model Terbaik	64
BAB V KESIMPULAN	67
5.1	Kesimpulan.....	67

5.2 Saran.....	67
DAFTAR PUSTAKA	69

DAFTAR GAMBAR

Gambar 2.1 Segmentasi Semantik[27]	9
Gambar 2.2 Segmentasi Instance[27]	10
Gambar 2.3 Segmentasi Panoptic[27]	11
Gambar 2.4 Deep Learning[8].....	12
Gambar 2.5 Arsitektur CNN[36]	13
Gambar 2.6 Arsitektur U-Net[39]	14
Gambar 2.7 Citra Pra-kanker Serviks.....	15
Gambar 3.1 Kerangka kerja.....	19
Gambar 3.2 Pembuatan ground truth	21
Gambar 3.3 Proses anotasi objek	23
Gambar 3.4 Folder data figure dan folder data ground truth.....	25

DAFTAR TABEL

Tabel 3.1 Rincian data yang akan digunakan.....	20
Tabel 3.2 Proses cropping gambar	20
Tabel 3.3 Objek Segmentasi.....	21
Tabel 3.4 Anotasi Objek.....	22
Tabel 3.5 Proses pembuatan label	23
Tabel 3.6 Ground truth	24
Tabel 3.7 Rincian pembagian data	25
Tabel 3.8 Konfigurasi parameter model.....	27
Tabel 4.1 Grafik pixel accuracy model U-Net-VGG16	29
Tabel 4.2 Grafik ROC dan PR model U-Net-VGG16.....	30
Tabel 4.3 Hasil evaluasi model U-Net-VGG16	31
Tabel 4.4 Inference model U-Net - VGG16.....	31
Tabel 4.5 Grafik pixel accuracy model U-Net-VGG19	32
Tabel 4.6 Grafik ROC dan PR model U-Net-VGG19.....	33
Tabel 4.7 Hasil evaluasi model U-Net-VGG19	34
Tabel 4.8 Inference model U-Net - VGG19.....	34
Tabel 4.9 Grafik pixel accuracy model U-Net - ResNet50	35
Tabel 4.10 Grafik ROC dan PR model U-Net - ResNet50	36
Tabel 4.11 Hasil evaluasi model U-Net - ResNet50	37
Tabel 4.12 Inference model U-Net - ResNet50.....	37
Tabel 4.13 Grafik pixel accuracy model U-Net - ResNext50	38
Tabel 4.14 Grafik ROC dan PR model U-Net - ResNext50	39
Tabel 4.15 Hasil evaluasi model U-Net - ResNext50	40
Tabel 4.16 Inference model U-Net - ResNext50.....	40
Tabel 4.17 Grafik pixel accuracy model U-Net - EfficientNetb7	41
Tabel 4.18 Grafik ROC dan PR model U-Net - EfficientNetb7	42
Tabel 4.19 Hasil evaluasi model U-Net - EfficientNetb7	43
Tabel 4.20 Inference model U-Net - EfficientNetb7.....	43
Tabel 4.21 Grafik pixel accuracy model U-Net - InceptionResNetv2	44
Tabel 4.22 Grafik ROC dan PR model U-Net - InceptionResNetv2	45
Tabel 4.23 Hasil evaluasi model U-Net - InceptionResNetv2	46

Tabel 4.24 Inference model U-Net - InceptionResNetv2.....	46
Tabel 4.25 Grafik pixel accuracy model U-Net - DenseNet201	47
Tabel 4.26 Grafik ROC dan PR model U-Net - DenseNet201	48
Tabel 4.27 Hasil evaluasi model U-Net - DenseNet201	49
Tabel 4.28 Inference model U-Net - DenseNet201.....	49
Tabel 4.29 Grafik pixel accuracy model U-Net - Inceptionv3.....	50
Tabel 4.30 Grafik ROC dan PR model U-Net - Inceptionv3	51
Tabel 4.31 Hasil evaluasi model U-Net - Inceptionv3.....	52
Tabel 4.32 Inference model U-Net - Inceptionv3	52
Tabel 4.33 Grafik pixel accuracy model U-Net - MobileNetv2.....	53
Tabel 4.34 Grafik ROC dan PR model U-Net - MobileNetv2.....	54
Tabel 4.35 Hasil evaluasi model U-Net - MobileNetv2.....	55
Tabel 4.36 Inference model U-Net - MobileNetv2	55
Tabel 4.37 Grafik pixel accuracy model U-Net - SEResNet50	56
Tabel 4.38 Grafik ROC dan PR model U-Net - SEResNet50.....	57
Tabel 4.39 Hasil evaluasi model U-Net - SEResNet50	58
Tabel 4.40 Inference model U-Net - SEResNet50.....	58
Tabel 4.41 Grafik pixel accuracy model U-Net - SEResNext50	59
Tabel 4.42 Grafik ROC dan PR model U-Net - SEResNext50.....	60
Tabel 4.43 Hasil evaluasi model U-Net - SEResNext50	61
Tabel 4.44 Inference model U-Net - SEResNext50.....	61
Tabel 4.45 Grafik pixel accuracy model U-Net - SENet154	62
Tabel 4.46 Grafik ROC dan PR model U-Net - SENet154.....	63
Tabel 4.47 Hasil evaluasi model U-Net - SENet154	64
Tabel 4.48 Inference model U-Net - SENet154.....	64
Tabel 4.49 Perbandingan model.....	65
Tabel 4. 50 Confusion Matrix	66

BAB I

PENDAHULUAN

1.1 Latar Belakang

Dalam beberapa dekade terakhir, *Artificial Intelligence* (AI) telah berkembang pesat dalam bidang *Computer Vision* (CV), yaitu cabang AI yang berfokus pada pemrosesan gambar dan video oleh komputer[1]. Kemajuan dalam teknologi *hardware* dan *software*, serta peningkatan ketersediaan data visual, telah memungkinkan pengembangan algoritma yang semakin canggih dan efektif dalam memproses dan menganalisis data visual[2]. Terdapat permintaan yang tinggi untuk aplikasi praktis dari CV untuk memproses data visual di berbagai industri termasuk dalam industri medis, AI digunakan untuk deteksi dini kanker serviks berdasarkan citra pra-kanker serviks[3].

Penggunaan AI dalam CV untuk deteksi kanker serviks telah menjadi area penelitian yang menjanjikan. Salah satu pendekatan yang dapat digunakan untuk deteksi kanker serviks adalah Segmentasi Citra[4]. Pendekatan Segmentasi Citra dalam deteksi kanker serviks memanfaatkan kemampuan kecerdasan buatan dalam bidang CV untuk memisahkan area lesi atau daerah yang menarik perhatian pada citra serviks. Dengan memisahkan area-area tertentu pada citra, segmentasi citra dapat membantu meningkatkan akurasi dan efisiensi dalam proses deteksi kanker serviks[5].

Seiring dengan kemajuan teknologi, model *Deep Learning* (DL) dapat diimplementasikan dalam proses segmentasi citra. Model DL telah menunjukkan kinerja yang baik dalam mengatasi berbagai masalah di bidang CV, seperti segmentasi citra[6]. Dalam hal segmentasi citra, model DL dapat dilatih untuk mempelajari pola-pola tertentu pada citra dan memisahkan area yang menarik perhatian pada citra, seperti area lesi atau daerah yang memungkinkan terdapat kanker serviks. Metode DL dalam segmentasi citra telah terbukti memberikan hasil yang lebih akurat dibandingkan dengan metode segmentasi tradisional[7].

Arsitektur dari model DL seperti U-Net, Mask R-CNN, atau metode berbasis pemrosesan citra seperti pengolahan tepi (*edge detection*) atau pemisahan warna (*color-based segmentation*), dapat digunakan untuk memisahkan daerah-daerah yang mencurigakan dari latar belakang serviks[8]. Pada penelitian [9] dan [10] telah membuktikan penggunaan algoritma DL yaitu *Mask-RCNN* dapat menghasilkan performa model segmentasi *instance* pada citra serviks yang optimal. Penelitian [9] menghasilkan nilai *Intersection over Union* (IoU), *Dice Score Similarity* (DSC) dan *Mean Average Precision* (mAP) untuk area SSK dan area lesi masing-masing 70,57%, 68,51%, 98,10% dan 60,44%, 68,51%, 98,85%. Penelitian [10] menghasilkan nilai IoU, DSC, mAP untuk area CA dan area lesi AW masing-masing 63.60%, 75.67%, 86.90% dan 73.98%, 80.49%, 100%.

Pada penelitian [11] melakukan segmentasi multikelas *end-to-end* organ berisiko menggunakan arsitektur DL yaitu *U-Net*. Penelitian ini menggunakan 105 gambar *Computed Tomography* (CT) pasien kanker serviks stadium lanjut untuk mensegmentasi tujuh organ yang berisiko. Hasilnya didapatkan nilai rata-rata DSC adalah 0,924, 0,854, 0,906, 0,900, 0,791, 0,833 dan 0,827 untuk masing-masing tujuh organ berisiko. Pada penelitian yang dilakukan oleh [12] juga melakukan segmentasi serviks rahim dengan membandingkan dua arsitektur segmentasi DL canggih yaitu *Mask-RCNN* dan *Mask X-RCNN* serta memakai jaringan *backbone* menggunakan arsitektur *ResNet50* dan *ResNet101*. Adapun penelitian tersebut menggunakan tiga dataset citra serviks yaitu dataset *Costa Rica Vaccine Trial* (CVT), dataset *Atypical Squamous Cells of Undetermined Significance/Low-grade Squamous Intraepithelial Lesion Triage Study* (ALTS) dan dataset Kaggle. Dari hasil pengujian model pada keseluruhan dataset, didapatkan model terbaik yaitu Mask R-CNN dengan nilai DSC dan IOU masing-masing didapatkan sebesar 0,947 dan 0,901.

Berdasarkan pada beberapa penelitian terdahulu yang telah dilakukan, membuktikan bahwa arsitektur-arsitektur dari model DL merupakan arsitektur yang canggih untuk melakukan pendekatan segmentasi citra. Oleh karena itu, akan dilakukan penelitian mengenai Segmentasi Semantik Multiclass pada Citra Pra-Kanker Serviks Menggunakan *Deep Learning*.

1.3 Tujuan

Tujuan dari penelitian dalam tugas akhir ini adalah sebagai berikut:

1. Dapat merancang model segmentasi semantik pada citra pra-kanker serviks menggunakan DL.
2. Dapat mengukur hasil kinerja model dengan menggunakan metrik evaluasi IoU, DSC dan *Pixel Accuracy*.

1.4 Manfaat

Manfaat dari penyusunan tugas akhir ini adalah sebagai berikut:

1. Menghasilkan model DL terbaik dengan menggunakan arsitektur *U-Net* dan *backbone*.
2. Sebagai bahan bacaan dan referensi untuk penelitian masa depan pada topik segmentasi semantik multi-kelas, baik untuk pra-kanker serviks maupun untuk objek segmentasi lain. (Jika dikembangkan menjadi software dapat mendukung tenaga medis)

1.5 Rumusan Masalah

Berdasarkan latar belakang dan tujuan penelitian ini dapat disimpulkan bahwa rumusan masalah pada penelitian ini adalah bagaimana model DL dapat digunakan untuk melakukan proses segmentasi semantik *multiclass* pada citra pra kanker serviks sehingga dapat membantu dalam mengambil keputusan terkait deteksi dini kanker serviks.

1.6 Batasan Masalah

Batasan masalah dalam penelitian pada tugas akhir ini adalah sebagai berikut:

1. Penelitian ini menggunakan data pasien dari Rumah Sakit Umum Pusat Dr. Mohammad Hoesin Palembang.

2. Objek yang akan digunakan pada data adalah Columnar, Lesi, Zona Transformasi dan Area Serviks.
3. Pendekatan yang digunakan adalah pendekatan DL dengan menggunakan arsitektur *U-Net* dengan *backbone*.
4. Backbone yang digunakan adalah *Vgg16*, *Vgg19*, *ResNet50*, *ResNext50*, *EfficientNetb7*, *InceptionResNetv2*, *DenseNet201*, *Inceptionv3*, *Mobilenetv2*, *Se-ResNet50*, *SE-ResNext50*, dan *SE-Net154*.
5. Hasil evaluasi kinerja untuk setiap model DL diukur dengan metrik evaluasi IoU, DSC dan *Pixel Accuracy*.

1.7 Sistematika Penelitian

Sistematika penulisan pada penelitian tugas akhir ini adalah sebagai berikut:

BAB I PENDAHULUAN

Pada bab ini, akan membahas mengenai latar belakang, tujuan dan manfaat, rumusan masalah, batasan masalah, metodologi penelitian dan sistematika penelitian dari topik penelitian.

BAB II TINJAUAN PUSTAKA

Pada bab ini, akan berisi penjelasan mengenai dasar teori dan materi yang digunakan untuk mendukung penulisan penelitian tugas akhir.

BAB III METODOLOGI PENELITIAN

Pada bab ini, akan berisi alur tahapan proses penelitian berupa kerangka kerja yang digunakan sebagai acuan langkah – langkah kegiatan yang akan dilakukan dalam penelitian tugas akhir.

BAB IV HASIL DAN PEMBAHASAN

Pada bab ini, akan berisi hasil yang diperoleh dari proses penelitian yang telah dilakukan berdasarkan kerangka kerja

beserta penjelasan analisa terhadap hasil penelitian tugas akhir.

BAB V **PENUTUP**

Pada bab ini, akan berisi penarikan kesimpulan dari hasil penelitian beserta saran untuk penelitian selanjutnya.

DAFTAR PUSTAKA

- [1] D. Kitaguchi, N. Takeshita, H. Hasegawa, and M. Ito, “Artificial intelligence-based computer vision in surgery: Recent advances and future perspectives,” *Ann. Gastroenterol. Surg.*, vol. 6, no. 1, pp. 29–36, Jan. 2022, doi: 10.1002/AGS3.12513.
- [2] X. Li and Y. Shi, “Computer vision imaging based on artificial intelligence,” *Proc. - 2018 Int. Conf. Virtual Real. Intell. Syst. ICVRIS 2018*, pp. 22–25, Nov. 2018, doi: 10.1109/ICVRIS.2018.00014.
- [3] X. Hou, G. Shen, L. Zhou, Y. Li, T. Wang, and X. Ma, “Artificial Intelligence in Cervical Cancer Screening and Diagnosis,” *Front. Oncol.*, vol. 12, Mar. 2022, doi: 10.3389/FONC.2022.851367.
- [4] A. Sarwar, A. A. Sheikh, J. Manhas, and V. Sharma, “Segmentation of cervical cells for automated screening of cervical cancer: a review,” *Artif. Intell. Rev.*, vol. 53, no. 4, pp. 2341–2379, Apr. 2020, doi: 10.1007/S10462-019-09735-2/METRICS.
- [5] H. Bandyopadhyay and M. Nasipuri, “Segmentation of Pap Smear Images for Cervical Cancer Detection,” *2020 IEEE Calcutta Conf. CALCON 2020 - Proc.*, pp. 30–33, Feb. 2020, doi: 10.1109/CALCON49167.2020.9106484.
- [6] S. Minaee, Y. Boykov, F. Porikli, A. Plaza, N. Kehtarnavaz, and D. Terzopoulos, “Image Segmentation Using Deep Learning: A Survey,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 44, no. 7, pp. 3523–3542, Jul. 2022, doi: 10.1109/TPAMI.2021.3059968.
- [7] M. H. Hesamian, W. Jia, X. He, and P. Kennedy, “Deep Learning Techniques for Medical Image Segmentation: Achievements and Challenges,” *J. Digit. Imaging*, vol. 32, no. 4, pp. 582–596, Aug. 2019, doi: 10.1007/S10278-019-00227-X/TABLES/2.
- [8] I. Rizwan I Haque and J. Neubert, “Deep learning approaches to biomedical image segmentation,” *Informatics Med. Unlocked*, vol. 18, p. 100297, Jan. 2020, doi: 10.1016/J.IMU.2020.100297.
- [9] S. FLORINA, GAVIRA OLIPA and Nurmaini, “INSTANCE SEGMENTATION SAMBUNGAN SKUAMO KOLUMNAR DAN LESI PADA DATA INSPEKSI VISUAL ASAM ASETAT MENGGUNAKAN MASK REGION CONVOLUTIONAL NEURAL,” vol. 2, no. 1, pp. 41–49, 2022, [Online]. Available: <http://repository.unsri.ac.id/id/eprint/69072>.
- [10] P. Agustiansyah *et al.*, “Automated Precancerous Lesion Screening Using an Instance Segmentation Technique for Improving Accuracy,” *Sensors 2022, Vol. 22, Page 5489*, vol. 22, no. 15, p. 5489, Jul. 2022, doi: 10.3390/S22155489.

- [11] Z. Liu *et al.*, “Segmentation of organs-at-risk in cervical cancer CT images with a convolutional neural network,” *Phys. Medica*, vol. 69, pp. 184–191, Jan. 2020, doi: 10.1016/J.EJMP.2019.12.008.
- [12] P. Guo, Z. Xue, L. Rodney Long, and S. Antani, “Cross-Dataset Evaluation of Deep Learning Networks for Uterine Cervix Segmentation,” *Diagnostics 2020, Vol. 10, Page 44*, vol. 10, no. 1, p. 44, Jan. 2020, doi: 10.3390/DIAGNOSTICS10010044.
- [13] P. Hamet and J. Tremblay, “Artificial intelligence in medicine,” *Metabolism*, vol. 69, pp. S36–S40, Apr. 2017, doi: 10.1016/J.METABOL.2017.01.011.
- [14] T. Davenport and R. Kalakota, “The potential for artificial intelligence in healthcare,” *Futur. Healthc. J.*, vol. 6, no. 2, p. 94, Jun. 2019, doi: 10.7861/FUTUREHOSP.6-2-94.
- [15] C. Grosan and A. Abraham, “Rule-Based Expert Systems,” *Intell. Syst. Ref. Libr.*, vol. 17, pp. 149–185, 2011, doi: 10.1007/978-3-642-21004-4_7/COVER.
- [16] P. Ongsulee, “Artificial intelligence, machine learning and deep learning,” *Int. Conf. ICT Knowl. Eng.*, pp. 1–6, Jan. 2018, doi: 10.1109/ICTKE.2017.8259629.
- [17] T. J. Sejnowski, “The unreasonable effectiveness of deep learning in artificial intelligence,” *Proc. Natl. Acad. Sci.*, vol. 117, no. 48, pp. 30033–30038, Dec. 2020, doi: 10.1073/PNAS.1907373117.
- [18] Q. Chen *et al.*, “Artificial Intelligence in Action: Addressing the COVID-19 Pandemic with Natural Language Processing,” <https://doi.org/10.1146/annurev-biodatasci-021821-061045>, vol. 4, pp. 313–339, Jul. 2021, doi: 10.1146/ANNUREV-BIODATASCI-021821-061045.
- [19] A. Esteva *et al.*, “Deep learning-enabled medical computer vision,” *npj Digit. Med.* 2021 41, vol. 4, no. 1, pp. 1–9, Jan. 2021, doi: 10.1038/s41746-020-00376-2.
- [20] X. Feng, Y. Jiang, X. Yang, M. Du, and X. Li, “Computer vision algorithms and hardware implementations: A survey,” *Integration*, vol. 69, pp. 309–320, Nov. 2019, doi: 10.1016/J.VLSI.2019.07.005.
- [21] S. Ghosh, N. Das, I. Das, and U. Maulik, “Understanding deep learning techniques for image segmentation,” *ACM Comput. Surv.*, vol. 52, no. 4, 2019, doi: 10.1145/3329784.
- [22] F. Sultana, A. Sufian, and P. Dutta, “Evolution of Image Segmentation using Deep Convolutional Neural Network: A Survey,” *Knowledge-Based Syst.*, vol. 201–202, p. 106062, Aug. 2020, doi: 10.1016/J.KNOSYS.2020.106062.
- [23] S. Pare, A. Kumar, G. K. Singh, and V. Bajaj, “Image Segmentation Using

- Multilevel Thresholding: A Research Review,” *Iran. J. Sci. Technol. - Trans. Electr. Eng.*, vol. 44, no. 1, pp. 1–29, Mar. 2020, doi: 10.1007/S40998-019-00251-1/METRICS.
- [24] N. Nida, A. Irtaza, A. Javed, M. H. Yousaf, and M. T. Mahmood, “Melanoma lesion detection and segmentation using deep region based convolutional neural network and fuzzy C-means clustering,” *Int. J. Med. Inform.*, vol. 124, pp. 37–48, Apr. 2019, doi: 10.1016/J.IJMEDINF.2019.01.005.
 - [25] H. Yu *et al.*, “Methods and datasets on semantic segmentation: A review,” *Neurocomputing*, vol. 304, pp. 82–103, Aug. 2018, doi: 10.1016/J.NEUCOM.2018.03.037.
 - [26] H. Sheng, R. Cong, D. Yang, R. Chen, S. Wang, and Z. Cui, “UrbanLF: A Comprehensive Light Field Dataset for Semantic Segmentation of Urban Scenes,” *IEEE Trans. Circuits Syst. Video Technol.*, vol. 32, no. 11, pp. 7880–7893, 2022, doi: 10.1109/TCSVT.2022.3187664.
 - [27] S. Hao, Y. Zhou, and Y. Guo, “A Brief Survey on Semantic Segmentation with Deep Learning,” *Neurocomputing*, vol. 406, pp. 302–321, Sep. 2020, doi: 10.1016/J.NEUCOM.2019.11.118.
 - [28] A. M. Hafiz and G. M. Bhat, “A survey on instance segmentation: state of the art,” *Int. J. Multimed. Inf. Retr.*, vol. 9, no. 3, pp. 171–189, Sep. 2020, doi: 10.1007/S13735-020-00195-X/METRICS.
 - [29] Z. Tian, C. Shen, and H. Chen, “Conditional Convolutions for Instance Segmentation,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 12346 LNCS, pp. 282–298, 2020, doi: 10.1007/978-3-030-58452-8_17/TABLES/6.
 - [30] X. Li and D. Chen, “A survey on deep learning-based panoptic segmentation,” *Digit. Signal Process.*, vol. 120, p. 103283, Jan. 2022, doi: 10.1016/J.DSP.2021.103283.
 - [31] O. Elharrouss, S. Al-Maadeed, N. Subramanian, N. Ottakath, N. Almaadeed, and Y. Himeur, “Panoptic Segmentation: A Review,” Nov. 2021, Accessed: May 09, 2023. [Online]. Available: <https://arxiv.org/abs/2111.10250v1>.
 - [32] I. Rizwan I Haque and J. Neubert, “Deep learning approaches to biomedical image segmentation,” *Informatics Med. Unlocked*, vol. 18, p. 100297, 2020, doi: 10.1016/j.imu.2020.100297.
 - [33] S. Dong, P. Wang, and K. Abbas, “A survey on deep learning and its applications,” *Comput. Sci. Rev.*, vol. 40, p. 100379, May 2021, doi: 10.1016/J.COSREV.2021.100379.
 - [34] Z. Liu *et al.*, “Deep learning based brain tumor segmentation: a survey,” doi: 10.1007/s40747-022-00815-5.
 - [35] N. Sharma, V. Jain, and A. Mishra, “An Analysis Of Convolutional Neural

- Networks For Image Classification," *Procedia Comput. Sci.*, vol. 132, pp. 377–384, Jan. 2018, doi: 10.1016/J.PROCS.2018.05.198.
- [36] Q. Li, W. Cai, X. Wang, Y. Zhou, D. D. Feng, and M. Chen, "Medical image classification with convolutional neural network," *2014 13th Int. Conf. Control Autom. Robot. Vision, ICARCV 2014*, pp. 844–848, 2014, doi: 10.1109/ICARCV.2014.7064414.
 - [37] M. K. Anbudevi and K. Suganthi, "Review of Semantic Segmentation of Medical Images Using Modified Architectures of UNET Figure 1 . Application of UNET medical Semantic segmentation is the classification of feature Due to the lack of image detail , it is impossible to derive pr semantic f," 2022.
 - [38] L. Cai, J. Gao, and D. Zhao, "A review of the application of deep learning in medical image classification and segmentation," *Ann. Transl. Med.*, vol. 8, no. 11, pp. 713–713, 2020, doi: 10.21037/atm.2020.02.44.
 - [39] G. Du, X. Cao, J. Liang, X. Chen, and Y. Zhan, "Medical image segmentation based on U-Net: A review," *J. Imaging Sci. Technol.*, vol. 64, no. 2, pp. 1–12, 2020, doi: 10.2352/J.ImagingSci.Technol.2020.64.2.020508.
 - [40] X. Liu, Z. Deng, and Y. Yang, "Recent progress in semantic image segmentation," *Artif. Intell. Rev.*, vol. 52, no. 2, pp. 1089–1106, Aug. 2019, doi: 10.1007/S10462-018-9641-3/FIGURES/12.
 - [41] X. Liu, Z. Deng, and Y. Yang, "Recent progress in semantic image segmentation," *Artif. Intell. Rev.*, vol. 52, no. 2, pp. 1089–1106, Aug. 2019, doi: 10.1007/S10462-018-9641-3/FIGURES/12.
 - [42] X. Zheng, Q. Lei, R. Yao, Y. Gong, and Q. Yin, "Image segmentation based on adaptive K-means algorithm," doi: 10.1186/s13640-018-0309-3.
 - [43] R. R. Shamir, Y. Duchin, J. Kim, G. Sapiro, and N. Harel, "Continuous Dice Coefficient: a Method for Evaluating Probabilistic Segmentations," Jun. 2019, doi: 10.48550/arxiv.1906.11031.
 - [44] S. Gonzalez, C. Arellano, and J. E. Tapia, "Deepblueberry: Quantification of Blueberries in the Wild Using Instance Segmentation," *IEEE Access*, vol. 7, pp. 105776–105788, 2019, doi: 10.1109/ACCESS.2019.2933062.
 - [45] S. Sudha, K. B. Jayanthi, C. Rajasekaran, and T. Sunder, "Segmentation of RoI in Medical Images Using CNN- A Comparative Study," *IEEE Reg. 10 Annu. Int. Conf. Proceedings/TENCON*, vol. 2019-October, pp. 767–771, Oct. 2019, doi: 10.1109/TENCON.2019.8929648.