

SEGMENTASI DAN DETEKSI KELAINAN JANTUNG ANAK DENGAN PANDANGAN 4 CHAMBER VIEW

SKRIPSI

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



OLEH :

**M. RIZKY ADITYA UTAMA
09011281722030**

**JURUSAN SISTEM KOMPUTER
FAKULTAS ILMU KOMPUTER
UNIVERSITAS SRIWIJAYA
2022**

SEGMENTASI DAN DETEKSI KELAINAN JANTUNG ANAK DENGAN PANDANGAN 4 CHAMBER VIEW

SKRIPSI

Diajukan Untuk Melengkapi Salah Satu Syarat

Memperoleh Gelar Sarjana Komputer



Oleh:

M. RIZKY ADITYA UTAMA

09011281722030

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

2022

HALAMAN PENGESAHAN

SEGMENTASI DAN DETEKSI KELAINAN JANTUNG ANAK DENGAN PANDANGAN 4 CHAMBER VIEW

SKRIPSI

Diajukan Untuk Melengkapi Salah Satu Syarat
Memperoleh Gelar Sarjana Komputer

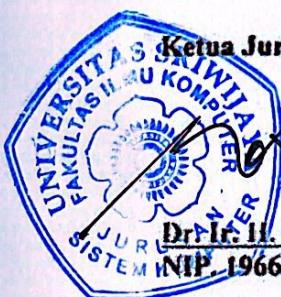
Oleh:

M. RIZKY ADITYA UTAMA

09011281722030

Indralaya, 23 November 2022

Mengetahui,



Pembimbing Tugas Akhir,

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

HALAMAN PERSETUJUAN

Telah diuji dan lulus pada :

Hari : Rabu

Tanggal : 05 Oktober 2022

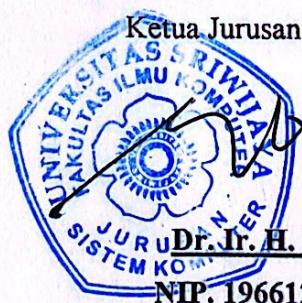
Tim Penguji :

1. Ketua Sidang : Dr. Firdaus, M.Kom.
2. Sekretaris Sidang : Aditya Putra Perdana P, M.T
3. Penguji Sidang : Sutarno, M.T
4. Pembimbing I : Prof. Dr. Ir. Siti Nurmaini, M.T

[Handwritten signatures of the committee members over four horizontal lines]

Mengetahui,

Ketua Jurusan Sistem Komputer



Dr. Ir. H. Sukemi, M.T.

NIP. 196612032006041001

HALAMAN PERNYATAAN

Yang bertanda tangan di bawah ini :

Nama : M. Rizky Aditya Utama

NIM : 09011281722030

Judul : Segmentasi dan Deteksi Kelainan Jantung Anak Dengan Pandangan 4 Chamber View

Hasil Penyecekan Software iThenticate/Turnitin : 5%

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.



Indralaya, November 2022



M. Rizky Aditya Utama
NIM. 09011281722030

KATA PENGANTAR

Assalamu'alaikum Warahmatullah Wabarakatuh. Puji beserta syukur penulis panjatkan kepada Allah Subhanahu Wa Ta'ala yang telah melimpahkan karunia, berkat, dan rahmat-Nya yang sangat besar dan tidak pernah berhenti kepada penulis, sehingga penulis dapat menyelesaikan tugas akhir ini yang berjudul **"Segmentasi dan Deteksi Kelainan Jantung Anak Dengan Pandangan 4 Chamber View"**.

Pada penyusunan laporan ini, penulis banyak mendapatkan ide dan saran serta bantuan dari berbagai pihak baik secara langsung maupun tidak langsung. Oleh karena itu, pada kesempatan ini penulis mengucapkan rasa syukur kepada Allah Subhanahu Wa Ta'ala dan terimakasih kepada yang terhormat:

1. Kedua orang tua saya yang selalu mendoakan, memberikan dukungan baik moril maupun materil, motivasi serta mengingatkan saya untuk menyelesaikan penulisan tugas akhir ini.
2. Bapak Jaidan Jauhari, S.Pd. M.T., selaku Dekan Fakultas Ilmu Komputer Universitas Sriwijaya.
3. Bapak Dr. Ir. H. Sukemi M.T., selaku Ketua Jurusan Sistem Komputer Fakultas Ilmu Komputer Universitas Sriwijaya.
4. Ibu Prof. Dr. Ir. Siti Nurmaini, M.T., selaku Pembimbing Tugas Akhir Penulis.
5. Bapak Ahmad Zarkasi, M.T., selaku Pembimbing Akademik Jurusan Sistem Komputer.
6. Pak Firdaus, Kak Naufal, Mbak Ade, Mbak Annisa dan semua teman-teman yang tergabung dalam grup riset citra ISYSRG BATCH II yang turut membantu memberikan arahan serta nasihat.
7. Adhitya Resky yang telah membantu penulis dalam mengerjakan tugas akhir ini dan memberikan dukungannya sampai akhir.

8. Tara Arsyad yang selalu memberikan dukungan moril dan memberikan nasihat pada saya agar terus berusaha untuk menyelesaikan penulisan tugas akhir ini.
9. Wangi Irlianti yang telah memberikan dukungan dan membantu dalam penulisan tugas akhir ini.
10. Kak Mutiara yang tak henti-hentinya mengingatkan saya untuk menyelesaikan penulisan tugas akhir ini.
11. Jo, Irvan, Iqbal dan Ikhsan sebagai teman yang banyak membantu penulis dalam hal nasihat dan menemani penulis dari awal perkuliahan.
12. Teman - teman dari Jurusan Sistem Komputer yang tidak bisa disebutkan satu-persatu. Khususnya seluruh teman-teman dari kelas SK17B Indralaya.
13. Dan semua pihak yang telah membantu.

Penulis menyadari bahwa tugas akhir ini masih jauh dari kesempurnaan, oleh karena itu penulis sangat mengharapkan kritik dan saran yang bersifat membangun agar lebih baik lagi dikemudian hari. Akhir kata dengan segala keterbatasan, penulis berharap semoga laporan ini menghasilkan sesuatu yang bermanfaat bagi kita semua khususnya bagi mahasiswa Fakultas Ilmu Komputer Universitas Sriwijaya secara langsung ataupun tidak langsung sebagai sumbangan pemikiran dalam peningkatan mutu pembelajaran dan penelitian.

Palembang, Agustus 2022

Penulis,

M. Rizky Aditya Utama

NIM. 09011281722030

Segmentasi dan Deteksi Kelainan Jantung Anak Dengan Pandangan 4 Chamber View

M. Rizky Aditya Utama (09011281722030)
Jurusan Sistem Komputer, Fakultas Ilmu Komputer,
Universitas Sriwijaya
Email : mrizkyadityautama@gmail.com

Abstrak

Belakangan ini pendekatan berbasis *Deep Learning* pada bidang medis telah menghadirkan kinerja yang sangat baik dalam segmentasi dan deteksi objek. Dalam metode berbasis komputer, segmentasi citra adalah cara mendasar untuk mengekstrak informasi yang berguna dari citra medis. Deteksi objek sebagai inti dari masalah penelitian *computer vision*, telah menarik banyak perhatian dari para peneliti. Penelitian yang berkaitan dengan kelainan jantung anak belum umum dilakukan karena data citra medis jantung anak sedikit sekali untuk diakses orang banyak. Data yang digunakan merupakan video ultrasonografi jantung anak dengan cara pandang four chamber view. Data tersebut dikonversi menjadi frame, anotasi, dan augmentasi data sebelum digunakan. *Convolutional Neural Network* sebagian telah diterapkan dengan hasil yang menjanjikan pada berbagai masalah pencitraan biomedis. Pada segmentasi citra medis dalam beberapa tahun terakhir sebagian besar kredit diberikan kepada Unet. Sedangkan untuk kasus deteksi objek, *Faster R-CNN* menjadi salah satu cara terbaik untuk mendeteksi objek. Pada kasus penelitian segmentasi yang dilakukan, model terbaik mendapatkan IoU sebesar 97.76 dan DSC 97.89. Pada kasus Deteksi objek, ekstraksi fitur yang digunakan adalah VGG16 dan ResNet50. Pada kasus deteksi pertama yang dilakukan, model yang menggunakan Resnet50 lebih baik dibanding VGG16. Model tersebut mendapatkan mAP sebesar 95.67%. Namun, pada kasus deteksi kedua model yang menggunakan VGG16 menjadi model terbaik dengan mAP 82.38%

Kata kunci : Segmentasi, Deteksi Objek, *Faster R-CNN*, Unet, VGG16, Resnet50, Citra Medis, Ultrasonografi, Jantung Anak, 4 *Chamber View*.

Segmentation and Detection of Infant Heart Defects with 4 Chamber View

M. Rizky Aditya Utama (09011281722030)
Department of Computer Systems, Faculty of Computer Science,
Sriwijaya University
Email : mrizkyadityautama@gmail.com

Abstract

Recently, Deep Learning-based approaches in the medical field have brought excellent performance in segmentation and object detection. In computer-based methods, image segmentation is a fundamental way to extract useful information from medical images. Object detection, as the core of the computer vision research problem, has attracted much attention from researchers. Research related to infant heart defects has not been commonly conducted because the data of infant heart medical images are very few to be accessed by many people. The data used is a infant heart ultrasonography video with a four chamber view. The data is converted into frames, annotations, and data augmentation before use. Convolutional Neural Network has been partially applied with promising results on various biomedical imaging problems. In medical image segmentation in recent years most of the credit goes to Unet. As for the case of object detection, Faster R-CNN is one of the best ways to detect objects. In the case of segmentation research conducted, the best model gets an IoU of 97.76 and DSC of 97.89. In the case of object detection, the feature extraction used is VGG16 and ResNet50. In the first detection case performed, the model using Resnet50 was better than VGG16. The model obtained a mAP of 95.67%. However, in the second detection case, the model using VGG16 was the best model with an mAP of 82.38%.

Keywords : Segmentation, Object Detection, Faster R-CNN, Unet, VGG16, Resnet50, Medical Imaging, Ultrasonography, Infant Heart, 4 Chamber View.

DAFTAR ISI

HALAMAN PENGESAHAN.....	ii
HALAMAN PERSETUJUAN	iii
HALAMAN PERNYATAAN	iv
KATA PENGANTAR.....	v
ABSTRAK	vii
ABSTRACT	viii
DAFTAR ISI.....	ix
DAFTAR GAMBAR.....	xiii
DAFTAR TABEL	xviii
DAFTAR LAMPIRAN	xix
BAB I PENDAHULUAN.....	1
1.1. Latar Belakang	1
1.2. Tujuan dan Manfaat.....	3
1.2.1. Tujuan	3
1.2.2. Manfaat	4
1.3. Rumusan Masalah	4
1.4. Batasan Masalah.....	4
1.5. Sistematika Penulisan.....	5
BAB II TINJAUAN PUSTAKA.....	7
2.1. Jantung.....	7
2.2. Penyakit Jantung Bawaan.....	7
2.2.1 Atrial Septal Defect	8
2.2.2 Atrioventricular Septal Defect	9
2.3. Ultrasonography	9
2.4. <i>Artificial Intelligence (AI)</i>	11
2.5. Machine Learning.....	11
2.6. Deep Learning	12
2.7. Convolutional Neural Network	13
2.8. Unet	14
2.9. Faster R-CNN.....	15
2.10. Validasi performa	16
2.10.1 Pixel Accuracy.....	17
2.10.2 Intersection Over Union (IoU).....	17
2.10.3 Mean Accuracy	17
2.10.4 False Positive Rate.....	17

2.10.5 Precision.....	17
2.10.6 Recall	17
2.10.7 Dice Similarity Coefficient.....	18
2.10.8 Mean Average Precesion (mAP)	18
BAB III METODOLOGI	19
3.1. Pendahuluan	19
3.2. Kerangka Kerja.....	19
3.3. Studi Literatur.....	20
3.4. Pengambilan Data.....	20
3.5. Pra-Pengolahan.....	21
3.5.1 Konversi Video ke Gambar	21
3.5.2 Seleksi Data	22
3.5.3 Ground Truth data.....	22
3.5.4 Augmentasi data	23
3.5.5 Anotasi data	24
3.5.6 Pembagian Data Latih dan Data Uji	25
3.6. Unet	26
3.7. Faster R-CNN.....	28
3.7.1. Region Proposal Network	29
3.7.2. Fast R-CNN Network.....	31
3.8. <i>Hyperparameter</i>	32
3.8.1. Epoch.....	32
3.8.2. Batch Size.....	32
3.8.3. Fungsi <i>Loss</i>	32
3.8.4. <i>Optimizer</i>	33
3.8.5. <i>Learning rate</i>	35
3.9. Evaluasi	35
BAB IV HASIL DAN PEMBAHASAN	37
4.1 Hasil Segmentasi Jantung Anak Menggunakan Unet	37
4.1.1. Hasil Segmentasi Jantung Anak Menggunakan Model 1 Unet.....	38
4.1.2. Hasil Segmentasi Jantung Anak Menggunakan Model 2 Unet.....	38
4.1.3. Hasil Segmentasi Jantung Anak Menggunakan Model 3 Unet.....	39
4.1.4. Hasil Segmentasi Jantung Anak Menggunakan Model 4 Unet.....	40
4.1.5. Hasil Segmentasi Jantung Anak Menggunakan Model 5 Unet.....	40
4.1.6. Hasil Segmentasi Jantung Anak Menggunakan Model 6 Unet.....	41
4.1.7. Hasil Segmentasi Jantung Anak Menggunakan Model 7 Unet.....	41
4.1.8. Hasil Segmentasi Jantung Anak Menggunakan Model 8 Unet.....	42
4.1.9. Hasil Evaluasi Model Segmentasi Jantung Anak Menggunakan Unet	42
4.1.10. Contoh Frame Hasil Segmentasi Unet	43

4.2.	Hasil Deteksi Kelainan Jantung Anak Menggunakan Faster-RCNN.....	44
4.2.1.	Model Faster R-CNN VGG16 Adam MSE 0.00001	45
4.2.2.	Model Faster R-CNN VGG16 Adam MAE 0.00001.....	46
4.2.3.	Model Faster R-CNN VGG16 Adam MSE 0.0001	46
4.2.4.	Model Faster R-CNN VGG16 Adam MAE 0.0001.....	47
4.2.5.	Model Faster R-CNN VGG16 RMSprop MSE 0.00001	48
4.2.6.	Model Faster R-CNN VGG16 RMSprop MAE 0.00001.....	49
4.2.7.	Model Faster R-CNN VGG16 RMSprop MSE 0.0001	49
4.2.8.	Model Faster R-CNN VGG16 RMSprop MAE 0.0001.....	50
4.2.9.	Model Faster R-CNN VGG16 SGD MSE 0.001	51
4.2.10.	Model Faster R-CNN VGG16 SGD MAE 0.001	52
4.2.11.	Model Faster R-CNN VGG16 SGD MSE 0.01	52
4.2.12.	Model Faster R-CNN VGG16 SGD MAE 0.01	53
4.2.13.	Model Faster R-CNN Resnet50 Adam MSE 0.00001	54
4.2.14.	Model Faster R-CNN Resnet50 Adam MAE 0.00001	55
4.2.15.	Model Faster R-CNN Resnet50 Adam MSE 0.0001	55
4.2.16.	Model Faster R-CNN Resnet50 Adam MAE 0.0001	56
4.2.17.	Model Faster R-CNN Resnet50 RMSprop MSE 0.00001	57
4.2.18.	Model Faster R-CNN Resnet50 RMSprop MAE 0.00001	58
4.2.19.	Model Faster R-CNN Resnet50 RMSprop MSE 0.0001	58
4.2.20.	Model Faster R-CNN Resnet50 RMSprop MAE 0.0001	59
4.2.21.	Model Faster R-CNN Resnet50 SGD MSE 0.001	60
4.2.22.	Model Faster R-CNN Resnet50 SGD MAE 0.001	61
4.2.23.	Model Faster R-CNN Resnet50 SGD MSE 0.01	61
4.2.24.	Model Faster R-CNN Resnet50 SGD MAE 0.01	62
4.2.25.	Hasil Evaluasi Model Deteksi Faster R-CNN.....	64
4.2.26.	Contoh Frame Hasil Deteksi Faster R-CNN.....	66
4.2.27.	Contoh Frame Salah Deteksi Faster R-CNN	66
4.3.	Pengujian Sistem Faster R-CNN Kasus Deteksi Kelainan Jantung Anak Data Hasil Segmentasi.....	68
4.3.1.	Model Faster R-CNN VGG16 Adam MAE 0.0001	69
4.3.2.	Model Faster R-CNN VGG16 RMSprop MAE 0.00001.....	69
4.3.3.	Model Faster R-CNN VGG16 RMSprop MSE 0.0001	70
4.3.4.	Model Faster R-CNN VGG16 RMSprop MAE 0.0001	71
4.3.5.	Model Faster R-CNN Resnet50 Adam MAE 0.0001	72
4.3.6.	Model Faster R-CNN Resnet50 RMSprop MAE 0.00001	72
4.3.7.	Model Faster R-CNN Resnet50 RMSprop MSE 0.0001	73
4.3.8.	Model Faster R-CNN Resnet50 RMSprop MAE 0.0001	74
4.3.9.	Hasil Evaluasi Model Deteksi Kelainan Jantung Anak Data Hasil Segmentasi	75
4.3.10.	Contoh Frame Hasil Deteksi Kelainan Jantung Anak Data Hasil Segmentasi	76

4.3.11. Contoh Frame Hasil Salah Deteksi Kelainan Jantung Anak Data Hasil Segmentasi.....	76
4.3.12. Perbandingan model deteksi Faster R-CNN	77
4.4. Analisa Model Segmentasi Unet	78
4.5. Analisa Model Deteksi Faster R-CNN	78
BAB V KESIMPULAN	80
5.1 Kesimpulan.....	80
5.2 Saran	81
DAFTAR PUSTAKA	82

DAFTAR GAMBAR

Gambar 2. 1 Anatomi jantung tampak depan [17]	7
Gambar 2. 2 <i>Atrial Septal Defect</i> (ASD) [22]	8
Gambar 2. 3 Atrioventricular Septal Defect (AVSD) [24].....	9
Gambar 2. 4 Ultrasonografi jantung [28]	10
Gambar 2. 5 Ruang lingkup <i>Artificial Intelligence</i> [32].....	11
Gambar 2. 6 Tipe algoritma machine learning [34]	12
Gambar 2. 7 Arsitektur Convolutional Neural Network [38].....	13
Gambar 2. 8 <i>Convolutional Layer</i> [40]	13
Gambar 2. 9 <i>Max-pooling operation</i> [37]	14
Gambar 2. 10 Kerangka kerja Unet [43]	15
Gambar 2. 11 Kerangka kerja <i>Faster R-CNN</i> [45]	16
Gambar 3. 1 Kerangka kerja penelitian	19
Gambar 3. 2 Pra-pengolahan data.....	21
Gambar 3. 3 Proses <i>Ground Truth</i>	22
Gambar 3. 4 Proses Augmentasi	23
Gambar 3. 5 Contoh anotasi frame ASD	24
Gambar 3. 6 Contoh anotasi frame AVSD	25
Gambar 3. 7 Blok diagram dari VGG16.....	28
Gambar 4. 1 Grafik Akurasi dan <i>Loss</i> Proses Pelatihan dan Pengujian Model 1 Unet	38
Gambar 4. 2 Grafik Akurasi dan <i>Loss</i> Proses Pelatihan dan Pengujian Model 2 Unet	39
Gambar 4. 3 Grafik Akurasi dan <i>Loss</i> Proses Pelatihan dan Pengujian Model 3 Unet	39
Gambar 4. 4 Grafik Akurasi dan <i>Loss</i> Proses Pelatihan dan Pengujian Model 4 Unet	40
Gambar 4. 5 Grafik Akurasi dan <i>Loss</i> Proses Pelatihan dan Pengujian Model 5 Unet	40

Gambar 4. 6 Grafik Akurasi dan <i>Loss</i> Proses Pelatihan dan Pengujian Model 6 Unet	41
Gambar 4. 7 Grafik Akurasi dan <i>Loss</i> Proses Pelatihan dan Pengujian Model 8 Unet	42
Gambar 4. 8 Grafik Akurasi dan <i>Loss</i> Proses Pelatihan dan Pengujian Model 8 Unet	42
Gambar 4. 9 Contoh frame prediksi dari model Unet	43
Gambar 4. 10 Grafik model <i>loss</i> Faster R-CNN VGG16 Adam MSE 0.00001 dihadarkan RPN	45
Gambar 4. 11 Grafik model <i>loss</i> Faster R-CNN VGG16 Adam MSE 0.00001 dihadarkan <i>Classifier</i>	45
Gambar 4. 12 Grafik model <i>loss</i> Faster R-CNN VGG16 Adam MAE 0.00001 dihadarkan RPN	46
Gambar 4. 13 Grafik model <i>loss</i> Faster R-CNN VGG16 Adam MAE 0.00001 dihadarkan <i>Classifier</i>	46
Gambar 4. 14 Grafik model <i>loss</i> Faster R-CNN VGG16 Adam MSE 0.0001 dihadarkan RPN	46
Gambar 4. 15 Grafik model <i>loss</i> Faster R-CNN VGG16 Adam MSE 0.0001 dihadarkan <i>Classifier</i>	47
Gambar 4. 16 Grafik model <i>loss</i> Faster R-CNN VGG16 Adam MAE 0.0001 dihadarkan RPN	47
Gambar 4. 17 Grafik model <i>loss</i> Faster R-CNN VGG16 Adam MAE 0.0001 dihadarkan <i>Classifier</i>	47
Gambar 4. 18 Grafik model <i>loss</i> Faster R-CNN VGG16 RMSprop MSE 0.00001 dihadarkan RPN	48
Gambar 4. 19 Grafik model <i>loss</i> Faster R-CNN VGG16 RMSprop MSE 0.00001 dihadarkan <i>Classifier</i>	48
Gambar 4. 20 Grafik model <i>loss</i> Faster R-CNN VGG16 RMSprop MAE 0.00001 dihadarkan RPN	49
Gambar 4. 21 Grafik model <i>loss</i> Faster R-CNN VGG16 RMSprop MAE 0.00001 dihadarkan <i>Classifier</i>	49
Gambar 4. 22 Grafik model <i>loss</i> Faster R-CNN VGG16 RMSprop MSE 0.0001 dihadarkan RPN	49
Gambar 4. 23 Grafik model <i>loss</i> Faster R-CNN VGG16 RMSprop MSE 0.0001 dihadarkan <i>Classifier</i>	50

Gambar 4. 24 Grafik model <i>loss</i> Faster R-CNN VGG16 RMSprop MAE 0.0001 dihadarkan RPN	50
Gambar 4. 25 Grafik model <i>loss</i> Faster R-CNN VGG16 RMSprop MAE 0.0001 dihadarkan <i>Classifier</i>	50
Gambar 4. 26 Grafik model <i>loss</i> Faster R-CNN VGG16 SGD MSE 0.001 dihadarkan RPN	51
Gambar 4. 27 Grafik model <i>loss</i> Faster R-CNN VGG16 SGD MSE 0.001 dihadarkan <i>Classifier</i>	51
Gambar 4. 28 Grafik model <i>loss</i> Faster R-CNN VGG16 SGD MAE 0.001 dihadarkan RPN	52
Gambar 4. 29 Grafik model <i>loss</i> Faster R-CNN VGG16 SGD MAE 0.001 dihadarkan <i>Classifier</i>	52
Gambar 4. 30 Grafik model <i>loss</i> Faster R-CNN VGG16 SGD MSE 0.01 dihadarkan RPN	52
Gambar 4. 31 Grafik model <i>loss</i> Faster R-CNN VGG16 SGD MSE 0.01 dihadarkan <i>Classifier</i>	53
Gambar 4. 32 Grafik model <i>loss</i> Faster R-CNN VGG16 SGD MAE 0.01 dihadarkan RPN	53
Gambar 4. 33 Grafik model <i>loss</i> Faster R-CNN VGG16 SGD MAE 0.01 dihadarkan <i>Classifier</i>	53
Gambar 4. 34 Grafik model <i>loss</i> Faster R-CNN Resnet50 Adam MSE 0.00001 dihadarkan RPN	54
Gambar 4. 35 Grafik model <i>loss</i> Faster R-CNN Resnet50 Adam MSE 0.00001 dihadarkan <i>Classifier</i>	54
Gambar 4. 36 Grafik model <i>loss</i> Faster R-CNN Resnet50 Adam MAE 0.00001 dihadarkan RPN	55
Gambar 4. 37 Grafik model <i>loss</i> Faster R-CNN Resnet50 Adam MAE 0.00001 dihadarkan <i>Classifier</i>	55
Gambar 4. 38 Grafik model <i>loss</i> Faster R-CNN Resnet50 Adam MSE 0.0001 dihadarkan RPN	55
Gambar 4. 39 Grafik model <i>loss</i> Faster R-CNN Resnet50 Adam MSE 0.0001 dihadarkan <i>Classifier</i>	56
Gambar 4. 40 Grafik model <i>loss</i> Faster R-CNN Resnet50 Adam MAE 0.0001 dihadarkan RPN	56
Gambar 4. 41 Grafik model <i>loss</i> Faster R-CNN Resnet50 Adam MAE 0.0001 dihadarkan <i>Classifier</i>	56

Gambar 4. 42 Grafik model <i>loss</i> Faster R-CNN Resnet50 RMSprop MSE 0.00001 dihasilkan RPN	57
Gambar 4. 43 Grafik model <i>loss</i> Faster R-CNN Resnet50 RMSprop MSE 0.00001 dihasilkan <i>Classifier</i>	57
Gambar 4. 44 Grafik model <i>loss</i> Faster R-CNN Resnet50 RMSprop MAE 0.00001 dihasilkan RPN	58
Gambar 4. 45 Grafik model <i>loss</i> Faster R-CNN Resnet50 RMSprop MAE 0.00001 dihasilkan <i>Classifier</i>	58
Gambar 4. 46 Grafik model <i>loss</i> Faster R-CNN Resnet50 RMSprop MSE 0.0001 dihasilkan RPN	58
Gambar 4. 47 Grafik model <i>loss</i> Faster R-CNN Resnet50 RMSprop MSE 0.0001 dihasilkan <i>Classifier</i>	59
Gambar 4. 48 Grafik model <i>loss</i> Faster R-CNN Resnet50 RMSprop MAE 0.0001 dihasilkan RPN	59
Gambar 4. 49 Grafik model <i>loss</i> Faster R-CNN Resnet50 RMSprop MAE 0.0001 dihasilkan <i>Classifier</i>	59
Gambar 4. 50 Grafik model <i>loss</i> Faster R-CNN Resnet50 SGD MSE 0.001 dihasilkan RPN	60
Gambar 4. 51 Grafik model <i>loss</i> Faster R-CNN Resnet50 SGD MSE 0.001 dihasilkan <i>Classifier</i>	60
Gambar 4. 52 Grafik model <i>loss</i> Faster R-CNN Resnet50 SGD MAE 0.001 dihasilkan RPN	61
Gambar 4. 53 Grafik model <i>loss</i> Faster R-CNN Resnet50 SGD MAE 0.001 dihasilkan <i>Classifier</i>	61
Gambar 4. 54 Grafik model <i>loss</i> Faster R-CNN Resnet50 SGD MSE 0.01 dihasilkan RPN	61
Gambar 4. 55 Grafik model <i>loss</i> Faster R-CNN Resnet50 SGD MSE 0.01 dihasilkan <i>Classifier</i>	62
Gambar 4. 56 Grafik model <i>loss</i> Faster R-CNN Resnet50 SGD MAE 0.01 dihasilkan RPN	62
Gambar 4. 57 Grafik model <i>loss</i> Faster R-CNN Resnet50 SGD MAE 0.01 dihasilkan <i>Classifier</i>	62
Gambar 4. 58 Grafik model <i>loss</i> Faster R-CNN VGG16 Adam MAE 0.0001 dihasilkan RPN	69
Gambar 4. 59 Grafik model <i>loss</i> Faster R-CNN VGG16 Adam MAE 0.0001 dihasilkan <i>Classifier</i>	69

Gambar 4. 60 Grafik model <i>loss</i> Faster R-CNN VGG16 RMSprop MAE 0.00001 dihadarkan RPN	69
Gambar 4. 61 Grafik model <i>loss</i> Faster R-CNN VGG16 RMSprop MAE 0.00001 dihadarkan <i>Classifier</i>	70
Gambar 4. 62 Grafik model <i>loss</i> Faster R-CNN VGG16 RMSprop MSE 0.0001 dihadarkan RPN	70
Gambar 4. 63 Grafik model <i>loss</i> Faster R-CNN VGG16 RMSprop MSE 0.0001 dihadarkan <i>Classifier</i>	70
Gambar 4. 64 Grafik model <i>loss</i> Faster R-CNN VGG16 RMSprop MAE 0.0001 dihadarkan RPN	71
Gambar 4. 65 Grafik model <i>loss</i> Faster R-CNN VGG16 RMSprop MAE 0.0001 dihadarkan <i>Classifier</i>	71
Gambar 4. 66 Grafik model <i>loss</i> Faster R-CNN Resnet50 Adam MAE 0.0001 dihadarkan RPN	72
Gambar 4. 67 Grafik model <i>loss</i> Faster R-CNN Resnet50 Adam MAE 0.0001 dihadarkan <i>Classifier</i>	72
Gambar 4. 68 Grafik model <i>loss</i> Faster R-CNN Resnet50 RMSprop MAE 0.00001 dihadarkan RPN	72
Gambar 4. 69 Grafik model <i>loss</i> Faster R-CNN Resnet50 RMSprop MAE 0.00001 dihadarkan <i>Classifier</i>	73
Gambar 4. 70 Grafik model <i>loss</i> Faster R-CNN Resnet50 RMSprop MSE 0.0001 dihadarkan RPN	73
Gambar 4. 71 Grafik model <i>loss</i> Faster R-CNN Resnet50 RMSprop MSE 0.0001 dihadarkan <i>Classifier</i>	73
Gambar 4. 72 Grafik model <i>loss</i> Faster R-CNN Resnet50 RMSprop MAE 0.0001 dihadarkan RPN	74
Gambar 4. 73 Grafik model <i>loss</i> Faster R-CNN Resnet50 RMSprop MAE 0.0001 dihadarkan <i>Classifier</i>	74

DAFTAR TABEL

Tabel 3. 1 Deskripsi Video yang Digunakan	20
Tabel 3. 2 Informasi data setelah dikonversi.....	21
Tabel 3. 3 Informasi frame yang digunakan setelah seleksi.....	22
Tabel 3. 4 Frame yang telah di augmentasi pada data kasus segmentasi dan deteksi	23
Tabel 3. 5 Frame yang telah di augmentasi pada data latih kasus deteksi data hasil segmentasi	24
Tabel 3. 6 Deskripsi data yang telah dibagi untuk data latih dan data uji untuk kasus segmentasi	25
Tabel 3. 7 Deskripsi data yang telah dibagi untuk data latih dan data uji untuk kasus deteksi	26
Tabel 3. 8 Deskripsi data hasil segmentasi yang telah dibagi untuk data latih dan data uji	26
Tabel 3. 12 Parameter model Unet	27
Tabel 3. 13 Informasi layer Resnet50.....	29
Tabel 4. 1 Model Segmentasi Unet	37
Tabel 4. 2 Hasil Evaluasi Model Segmentasi Unet	43
Tabel 4. 3 Model Deteksi Faster R-CNN	44
Tabel 4. 4 Hasil evaluasi model deteksi Faster R-CNN	64
Tabel 4. 5 Contoh hasil deteksi Faster R-CNN	66
Tabel 4. 6 Contoh hasil salah deteksi Faster R-CNN.....	66
Tabel 4. 7 Model Deteksi Faster R-CNN	68
Tabel 4. 8 Hasil evaluasi model deteksi Faster R-CNN	75
Tabel 4. 9 Contoh hasil deteksi Faster R-CNN	76
Tabel 4. 10 Contoh hasil salah deteksi Faster R-CNN.....	76
Tabel 4. 11 Perbandingan model terbaik dari kedua kasus deteksi	77

DAFTAR LAMPIRAN

Turnitin	A
Verifikasi Suliet	B
Form Revisi	C

BAB I

PENDAHULUAN

1.1. Latar Belakang

Pencitraan medis membantu dokter dan tenaga medis lainnya dalam mengumpulkan informasi yang berguna untuk mendiagnosis penyakit, intervensi bedah, serta pengobatan dan tindak lanjut suatu penyakit. Untuk ekstraksi informasi klinis yang relevan seperti itu adalah suatu tugas yang kompleks. Oleh karena itu dibutuhkan sistem komputasi canggih yang mampu memproses dan memperoleh fitur berbasis gambar secara akurat dan konsisten dalam waktu sesingkat mungkin. Akibatnya, area penelitian baru telah muncul yang menggabungkan teknik komputasi yang digunakan untuk pemrosesan dan analisis citra medis [1]. Belakangan ini pendekatan berbasis *deep learning* pada bidang medis telah menghadirkan kinerja yang sangat baik dalam segmentasi dan deteksi objek [2].

Dalam metode berbasis computer, segmentasi citra adalah cara mendasar untuk mengekstrak informasi yang berguna dari citra medis dan untuk mengidentifikasi kelainan [3]. Segmentasi citra medis, mengidentifikasi piksel organ atau lesi dari background citra medis seperti citra USG, adalah salah satu tugas yang paling menantang dalam analisis citra medis untuk menyampaikan informasi penting tentang bentuk dan volume organ-organ ini. Namun, terdapat beberapa kendala pada segmentasi citra medis, seperti data yang tersedia hanya sedikit dan kelas yang tidak seimbang [4].

Penyakit jantung bawaan adalah kelainan bawaan yang paling sering ditemui. Jenis penyakit jantung bawaan yang parah mempengaruhi sekitar 2-3 bayi baru lahir per 1000 persalinan dan merupakan penyebab utama kematian [5]. Ultrasonografi (USG) adalah salah satu skema paling umum untuk mendeteksi kelainan dalam praktik klinis. Namun, membaca citra USG tidaklah mudah [6]. Biasanya, citra ultrasonografi dianalisis secara manual, proses ini memakan waktu dan hasilnya subjektif. Dalam pengaplikasiannya di dunia nyata, pada citra ultrasonografi terdapat banyak *noise*, sehingga lebih sulit untuk dikenali [7].

Sebagai masalah lama, mendasar dan menantang dalam *computer vision*, deteksi objek telah menjadi bidang penelitian yang aktif dalam beberapa dekade ini [8]. Deteksi objek sebagai inti dari masalah penelitian *computer vision*, telah menarik banyak perhatian dari para peneliti. Biasanya terdapat dua langkah pada deteksi objek, pertama mencari objek dalam gambar, dan kemudian menggunakan *bounding box* untuk menemukan objek, penggunaan *convolutional neural network* telah menghasilkan performa yang sangat baik dalam deteksi objek. Namun, karena latar belakang yang kompleks, halangan dan resolusi yang rendah, masih terdapat masalah dalam mendeteksi objek berukuran kecil [9].

Convolutional neural networks (CNN) adalah jenis jaringan syaraf tiruan *feedforward* yang menggunakan operasi matematika yang disebut konvolusi [10]. Secara khusus, CNN telah diterapkan dengan hasil yang menjanjikan pada berbagai masalah pencitraan biomedis [11]. CNN memiliki banyak aplikasi yang berhasil seperti pengenalan karakter tulisan tangan, deteksi objek, klasifikasi gambar skala besar dan pengenalan wajah [12].

Meskipun memulai terobosan dalam tugas *computer vision*, kelemahan utama dari CNN adalah mereka membutuhkan data pelatihan yang berjumlah besar. Tetapi, dalam konteks citra medis, untuk memperoleh data citra tidak mudah karena data yang tersedia untuk umum sedikit atau mahal. Namun demikian, CNN telah menunjukkan hasil yang menjanjikan dalam segmentasi citra medis dalam beberapa tahun terakhir, dan sebagian besar kredit diberikan kepada *U-Net* [13]. *U-Net* pertama kali diperkenalkan pada tahun 2015. Arsitektur ini dengan cepat berevolusi menjadi tolak ukur yang umum digunakan dalam segmentasi citra medis [14]. *U-Net* menggunakan jaringan lapisan konvolusi sepenuhnya untuk melakukan tugas segmentasi. Arsitektur jaringannya simetris, memiliki *encoder* yang mengekstrak fitur spasial dari gambar, dan *decoder* yang membangun peta segmentasi dari fitur yang dikodekan [13].

Faster R-CNN yang menggabungkan jaringan *Region Proposal Network* (RPN) dan jaringan *Fast R-CNN* adalah salah satu cara terbaik untuk mendeteksi objek dalam seri R-CNN berdasarkan *deep learning*. Proposal yang diperoleh RPN terhubung langsung ke lapisan *ROI Pooling*, yang merupakan kerangka kerja untuk CNN mencapai deteksi objek [15].

1.2. Tujuan dan Manfaat

1.2.1. Tujuan

Adapun tujuan dari penelitian ini adalah:

1. Penerapan arsitektur Unet dalam melakukan proses segmentasi citra jantung anak pada pandangan *4 chamber*.
2. Penerapan arsitektur *Faster-RCNN* dalam mendeteksi kelainan jantung anak pada pandangan *4 chamber*.

3. Analisa evaluasi model segmentasi ruang jantung anak menggunakan *metric evaluation* yang terdiri dari *Pixel Accuracy*, *IoU (Intersection Over Union)*, *Mean Accuracy*, *FPR*, *Precision*, *Recall*, dan *DSC (Dice Similarity Coefficient)*.
4. Analisa evaluasi model deteksi kelainan jantung anak menggunakan *Mean Average Precision* (mAP).

1.2.2. Manfaat

Adapun manfaat dari penulisan tugas akhir ini adalah sebagai berikut:

1. Membantu para tenaga medis untuk mensegmentasi bagian jantung anak.
2. Dapat dijadikan alat bantu dokter untuk mengambil keputusan diagnosis kelainan jantung anak.
3. Sebagai referensi pembelajaran untuk para akademisi dan penelitian dalam bidang citra dan kesehatan, terutama pada pengolahan Citra Digital (*Computer Vision*).

1.3. Rumusan Masalah

Bagaimana melakukan segmentasi citra jantung anak pada sudut pandang *4 chamber view* menggunakan *Unet* dan mendekripsi kelainan pada jantung anak menggunakan *Faster-RCNN*?

1. Bagaimana membangun model *Unet* agar mampu mensegmentasi jantung anak?
2. Bagaimana membangun model *Faster R-CNN* agar mampu mendekripsi kelainan jantung anak?
3. Bagaimana performa *Unet* dalam mensegmentasi ruang jantung anak?
4. Bagaimana nilai akurasi performa *Faster R-CNN* saat mendekripsi kelainan pada jantung anak?

1.4. Batasan Masalah

Adapun batasan masalah yang terdapat pada penelitian tugas akhir ini, yaitu:

1. Penelitian ini menggunakan data citra ultrasonografi jantung anak normal dan abnormal dengan sudut pandang *4 chamber view*.
2. Segmentasi hanya dilakukan terhadap ruang jantung.
3. Deteksi hanya dilakukan pada kelainan jantung anak.
4. Seberapa baik kinerja model ini tergantung faktor kualitas serta ukuran dataset.

1.5. Sistematika Penulisan

Sistematika yang digunakan dalam penulisan tugas akhir ini adalah sebagai berikut:

BAB I – PENDAHULUAN

Pada bab ini akan membahas Latar Belakang, Tujuan dan Manfaat, Rumusan dan Batasan Masalah, Metodologi Penelitian serta Sistematika Penulisan.

BAB II – TINJAUAN PUSTAKA

Pada bab ini akan membahas dasar teori yang menunjang pembahasan dari penelitian ini. Dasar teori ini berisi literatur dari penelitian sebelumnya mengenai Jantung, *Ultrasonography*, *Machine Learning*, *Deep Learning*, Segmentasi, Deteksi, dan Arsitektur model segmentasi maupun deteksi.

BAB III – METODOLOGI PENELITIAN

Pada bab ini akan membahas tahapan-tahapan penelitian yang akan dimulai dengan Pra-Pengolahan data hingga bagaimana metode mempelajari data.

BAB IV – HASIL DAN ANALISIS

Pada bab ini akan membahas hasil dan analisa dari kinerja segmentasi ruang jantung anak menggunakan Unet dan deteksi kelainan jantung anak menggunakan *Faster-RCNN* pada pandangan *4 chamber view*.

BAB V – KESIMPULAN DAN SARAN

Pada bab ini akan membahas kesimpulan yang didapat dari hasil dan analisa yang telah dilakukan mengenai segmentasi ruang jantung anak menggunakan Unet dan deteksi kelainan jantung anak menggunakan *Faster-RCNN* pada pandangan *4 chamber view*. Pada bab ini juga terdapat saran yang mungkin berguna untuk penelitian selanjutnya.

DAFTAR PUSTAKA

- [1] C. A. S. J. Gulo, A. C. Sementille, and J. M. R. S. Tavares, “Techniques of medical image processing and analysis accelerated by high-performance computing: a systematic literature review,” *J. Real-Time Image Process.*, vol. 16, no. 6, pp. 1891–1908, 2019, doi: 10.1007/s11554-017-0734-z.
- [2] T. Zhou, S. Ruan, and S. Canu, “A review: Deep learning for medical image segmentation using multi-modality fusion,” *Array*, vol. 3–4, no. July, p. 100004, 2019, doi: 10.1016/j.array.2019.100004.
- [3] G. A. Tsirhrintzis, M. Virvou, and L. C. Jain, *Intelligent Computing Systems*. 2016.
- [4] 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.
- [5] G. Palareti *et al.*, “Comparison between different D-Dimer cutoff values to assess the individual risk of recurrent venous thromboembolism: Analysis of results obtained in the DULCIS study,” *Int. J. Lab. Hematol.*, vol. 38, no. 1, pp. 42–49, 2016, doi: 10.1111/ijlh.12426.

- [6] Q. Huang, F. Zhang, and X. Li, “Machine Learning in Ultrasound Computer-Aided Diagnostic Systems: A Survey,” *Biomed Res. Int.*, vol. 2018, 2018, doi: 10.1155/2018/5137904.
- [7] X. Qi *et al.*, “Automated diagnosis of breast ultrasonography images using deep neural networks,” *Med. Image Anal.*, vol. 52, pp. 185–198, 2019, doi: 10.1016/j.media.2018.12.006.
- [8] L. Liu *et al.*, “Deep Learning for Generic Object Detection: A Survey,” *Int. J. Comput. Vis.*, vol. 128, no. 2, pp. 261–318, 2020, doi: 10.1007/s11263-019-01247-4.
- [9] C. Cao *et al.*, “An Improved Faster R-CNN for Small Object Detection,” *IEEE Access*, vol. 7, pp. 106838–106846, 2019, doi: 10.1109/ACCESS.2019.2932731.
- [10] E. Pérez, O. Reyes, and S. Ventura, “Convolutional neural networks for the automatic diagnosis of melanoma: An extensive experimental study,” *Med. Image Anal.*, vol. 67, 2021, doi: 10.1016/j.media.2020.101858.
- [11] K. Kamnitsas *et al.*, “Efficient multi-scale 3D CNN with fully connected CRF for accurate brain lesion segmentation,” *Med. Image Anal.*, vol. 36, pp. 61–78, 2017, doi: 10.1016/j.media.2016.10.004.

- [12] Z. Zhao and A. Kumar, “Accurate Periocular Recognition under Less Constrained Environment Using Semantics-Assisted Convolutional Neural Network,” *IEEE Trans. Inf. Forensics Secur.*, vol. 12, no. 5, pp. 1017–1030, 2017, doi: 10.1109/TIFS.2016.2636093.
- [13] 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.
- [14] F. Isensee *et al.*, “nnU-Net: Self-adapting Framework for U-Net-Based Medical Image Segmentation,” *Inform. aktuell*, p. 22, 2019, doi: 10.1007/978-3-658-25326-4_7.
- [15] B. Liu, W. Zhao, and Q. Sun, “Study of object detection based on Faster R-CNN,” *Proc. - 2017 Chinese Autom. Congr. CAC 2017*, vol. 2017-Janua, pp. 6233–6236, 2017, doi: 10.1109/CAC.2017.8243900.
- [16] M. Litviňuková *et al.*, “Cells of the adult human heart,” *Nature*, vol. 588, no. 7838, pp. 466–472, 2020, doi: 10.1038/s41586-020-2797-4.
- [17] V. Mahadevan, “Anatomy of the heart,” *Surg. (United Kingdom)*, vol. 36, no. 2, pp. 43–47, 2018, doi: 10.1016/j.mpsur.2017.11.010.

- [18] P. F. Sun, G. C. Ding, M. Y. Zhang, S. N. He, Y. Gao, and J. H. Wang, “Prevalence of congenital heart disease among infants from 2012 to 2014 in Langfang, China,” *Chin. Med. J. (Engl.)*, vol. 130, no. 9, pp. 1069–1073, 2017, doi: 10.4103/0366-6999.204923.
- [19] S. M. Gephart, E. F. Moore, and E. Fry, “Standardized Feeding Protocols to Reduce Risk of Necrotizing Enterocolitis in Fragile Infants Born Premature or with Congenital Heart Disease: Implementation Science Needed,” *Crit. Care Nurs. Clin. North Am.*, vol. 30, no. 4, pp. 457–466, 2018, doi: 10.1016/j.cnc.2018.07.003.
- [20] R. Abouk, S. D. Grosse, E. C. Ailes, and M. E. Oster, “Association of US State Implementation of Newborn Screening Policies for Critical Congenital Heart Disease with Early Infant Cardiac Deaths,” *JAMA - J. Am. Med. Assoc.*, vol. 318, no. 21, pp. 2111–2118, 2017, doi: 10.1001/jama.2017.17627.
- [21] D. Shi *et al.*, “Biodegradable atrial septal defect occluders: A current review,” *Acta Biomater.*, vol. 96, pp. 68–80, 2019, doi: 10.1016/j.actbio.2019.05.073.
- [22] M. C. Yang and J. R. Wu, “Recent review of transcatheter closure of atrial septal defect,” *Kaohsiung J. Med. Sci.*, vol. 34, no. 7, pp. 363–369, 2018, doi: 10.1016/j.kjms.2018.05.001.

- [23] R. K. Kharbanda *et al.*, “Incidence and risk factors of post-operative arrhythmias and sudden cardiac death after atrioventricular septal defect (AVSD) correction: Up to 47 years of follow-up,” *Int. J. Cardiol.*, vol. 252, pp. 88–93, 2018, doi: 10.1016/j.ijcard.2017.09.209.
- [24] A. Deri and K. English, “EDUCATIONAL SERIES IN CONGENITAL HEART DISEASE: Echocardiographic assessment of left to right shunts: atrial septal defect, ventricular septal defect, atrioventricular septal defect, patent arterial duct,” *Echo Res. Pract.*, vol. 5, no. 1, pp. R1–R16, 2018, doi: 10.1530/erp-17-0062.
- [25] M. Tomar, “Assessment of Atrioventricular Septal Defect on Echocardiography,” *J. Indian Acad. Echocardiogr. Cardiovasc. Imaging*, vol. 4, no. 3, p. 267, 2020, doi: 10.4103/jiae.jiae_69_20.
- [26] T. Apard, “Ultrasonography for the orthopaedic surgeon,” *Orthop. Traumatol. Surg. Res.*, vol. 105, no. 1, pp. S7–S14, 2019, doi: 10.1016/j.otsr.2018.04.027.
- [27] R. Mogra, “Simplifying ultrasound assessment of the fetal heart: Incorporating the complete Three Vessel View into routine screening,” *Australas. J. Ultrasound Med.*, vol. 16, no. 4, pp. 168–175, 2013, doi: 10.1002/j.2205-0140.2013.tb00243.x.

- [28] A. Sjaus and A. Fayad, “The Use of Subcostal Echocardiographic Views to Guide the Insertion of a Right Ventricular Temporary Transvenous Pacemaker—Description of the Technique,” *J. Cardiothorac. Vasc. Anesth.*, vol. 33, no. 10, pp. 2797–2803, 2019, doi: 10.1053/j.jvca.2019.01.033.
- [29] X. Zeng, L. Wen, B. Liu, and X. Qi, “Deep learning for ultrasound image caption generation based on object detection,” *Neurocomputing*, vol. 392, no. xxxx, pp. 132–141, 2020, doi: 10.1016/j.neucom.2018.11.114.
- [30] M. Haenlein and A. Kaplan, “A brief history of artificial intelligence: On the past, present, and future of artificial intelligence,” *Calif. Manage. Rev.*, vol. 61, no. 4, pp. 5–14, 2019, doi: 10.1177/0008125619864925.
- [31] T. M. Maddox, J. S. Rumsfeld, and P. R. O. Payne, “Questions for Artificial Intelligence in Health Care,” *JAMA - J. Am. Med. Assoc.*, vol. 321, no. 1, pp. 31–32, 2019, doi: 10.1001/jama.2018.18932.
- [32] C. Krittawong, H. J. Zhang, Z. Wang, M. Aydar, and T. Kitai, “Artificial Intelligence in Precision Cardiovascular Medicine,” *J. Am. Coll. Cardiol.*, vol. 69, no. 21, pp. 2657–2664, 2017, doi: 10.1016/j.jacc.2017.03.571.
- [33] B. Rao, “Machine Learning Algorithms: A Review,” *Int. J. Comput. Sci. Inf. Technol.*, vol. 7, no. 3, pp. 1174–1179, 2016, doi:

10.21275/ART20203995.

- [34] Y. E. Yoon, S. Kim, and H. J. Chang, “Artificial intelligence and echocardiography,” *J. Cardiovasc. Imaging*, vol. 29, no. 3, pp. 193–204, 2021, doi: 10.4250/jcv.2021.0039.
- [35] D. Tran, S. Cooke, P. J. Illingworth, and D. K. Gardner, “Deep learning as a predictive tool for fetal heart pregnancy following time-lapse incubation and blastocyst transfer,” *Hum. Reprod.*, vol. 34, no. 6, pp. 1011–1018, 2019, doi: 10.1093/humrep/dez064.
- [36] A. Kamilaris and F. X. Prenafeta-Boldú, “Deep learning in agriculture: A survey,” *Comput. Electron. Agric.*, vol. 147, no. February, pp. 70–90, 2018, doi: 10.1016/j.compag.2018.02.016.
- [37] S. Albawi, T. A. Mohammed, and S. Al-Zawi, “Understanding of a convolutional neural network,” *Proc. 2017 Int. Conf. Eng. Technol. ICET 2017*, vol. 2018-Janua, pp. 1–6, 2018, doi: 10.1109/ICEngTechnol.2017.8308186.
- [38] A. Madani, R. Arnaout, M. Mofrad, and R. Arnaout, “Fast and accurate view classification of echocardiograms using deep learning,” *npj Digit. Med.*, vol. 1, no. 1, pp. 1–8, 2018, doi: 10.1038/s41746-017-0013-1.

- [39] M. V. Valueva, N. N. Nagornov, P. A. Lyakhov, G. V. Valuev, and N. I. Chervyakov, “Application of the residue number system to reduce hardware costs of the convolutional neural network implementation,” *Math. Comput. Simul.*, vol. 177, pp. 232–243, 2020, doi: 10.1016/j.matcom.2020.04.031.
- [40] P. Kim, “MATLAB Deep Learning,” *MATLAB Deep Learn.*, no. November 2013, pp. 121–147, 2017, doi: 10.1007/978-1-4842-2845-6.
- [41] F. Sultana, A. Sufian, and P. Dutta, “Advancements in image classification using convolutional neural network,” *Proc. - 2018 4th IEEE Int. Conf. Res. Comput. Intell. Commun. Networks, ICRCICN 2018*, pp. 122–129, 2018, doi: 10.1109/ICRCICN.2018.8718718.
- [42] S. Qamar, H. Jin, R. Zheng, P. Ahmad, and M. Usama, “A variant form of 3D-UNet for infant brain segmentation,” *Futur. Gener. Comput. Syst.*, vol. 108, pp. 613–623, 2020, doi: 10.1016/j.future.2019.11.021.
- [43] A. Abdollahi, B. Pradhan, and A. M. Alamri, “An ensemble architecture of deep convolutional Segnet and Unet networks for building semantic segmentation from high-resolution aerial images,” *Geocarto Int.*, vol. 0, no. 0, p. 000, 2020, doi: 10.1080/10106049.2020.1856199.
- [44] Q. X. Zhang, G. H. Lin, Y. M. Zhang, G. Xu, and J. J. Wang, “Wildland

Forest Fire Smoke Detection Based on Faster R-CNN using Synthetic Smoke Images,” *Procedia Eng.*, vol. 211, pp. 441–446, 2018, doi: 10.1016/j.proeng.2017.12.034.

- [45] H. Huang, H. Zhou, X. Yang, L. Zhang, L. Qi, and A. Y. Zang, “Faster R-CNN for marine organisms detection and recognition using data augmentation,” *Neurocomputing*, vol. 337, pp. 372–384, 2019, doi: 10.1016/j.neucom.2019.01.084.
- [46] S. Ren, K. He, R. Girshick, and J. Sun, “Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks,” in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, vol. 39, no. 6, pp. 1137–1149, doi: 10.1109/TPAMI.2016.2577031.
- [47] S. Sivagami, P. Chitra, G. S. R. Kailash, and S. R. Muralidharan, “UNet Architecture Based Dental Panoramic Image Segmentation,” *2020 Int. Conf. Wirel. Commun. Signal Process. Networking, WiSPNET 2020*, pp. 187–191, 2020, doi: 10.1109/WiSPNET48689.2020.9198370.
- [48] S. Ren, K. He, and R. Girshick, “Faster R-CNN : Towards Real-Time Object Detection with Region Proposal Networks,” pp. 1–9.
- [49] Z. Song, L. Fu, J. Wu, Z. Liu, R. Li, and Y. Cui, “Kiwifruit detection in field images using Faster R-CNN with VGG16 Kiwifruit detection in field

images using Faster R-CNN with VGG16 Kiwifruit detection in field images using Faster R-CNN with VGG16,” *IFAC Pap.*, vol. 52, no. 30, pp. 76–81, 2019, doi: 10.1016/j.ifacol.2019.12.500.

- [50] I. Z. Mukti and D. Biswas, “Transfer Learning Based Plant Diseases Detection Using ResNet50,” *2019 4th Int. Conf. Electr. Inf. Commun. Technol. EICT 2019*, no. December, pp. 1–6, 2019, doi: 10.1109/EICT48899.2019.9068805.
- [51] S. Hira, A. Bai, and S. Hira, “An automatic approach based on CNN architecture to detect Covid-19 disease from chest X-ray images,” *Appl. Intell.*, vol. 51, no. 5, pp. 2864–2889, 2021, doi: 10.1007/s10489-020-02010-w.
- [52] D. Kang, S. Park, and J. Paik, “SdBAN: Salient Object Detection Using Bilateral Attention Network with Dice Coefficient Loss,” *IEEE Access*, vol. 8, pp. 104357–104370, 2020, doi: 10.1109/ACCESS.2020.2999627.
- [53] J. Leng, Y. Ren, W. Jiang, X. Sun, and Y. Wang, “Realize your surroundings: Exploiting context information for small object detection,” *Neurocomputing*, vol. 433, pp. 287–299, 2021, doi: 10.1016/j.neucom.2020.12.093.