

**PENGENALAN POLA PANDANGAN JANTUNG
JANIN MENGGUNAKAN ARSITEKTUR
*FASTER R-CNN***

TUGAS AKHIR

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



OLEH :

M. ADHITYA RESKI PRATAMA. R

09011281722036

**JURUSAN SISTEM KOMPUTER
FAKULTAS ILMU KOMPUTER
UNIVERSITAS SRIWIJAYA
2021**

HALAMAN PENGESAHAN

**Pengenalan Pola Pandangan Jantung Janin
Menggunakan Arsitektur *FASTER R-CNN***

TUGAS AKHIR

Program Studi Sistem Komputer

Jenjang S1

Oleh :

M.ADHITYA RESKI PRATAMA, R

09011281722036

Palembang, Juli 2021

Mengetahui,

Ketua Jurusan Sistem Komputer,



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

Pembimbing Tugas Akhir,

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

HALAMAN PERSETUJUAN

Telah diuji dan lulus pada:

Hari : Jum'at

Tanggal : 29 Juli 2021

Tim Penguji:

1. Ketua Sidang : Sutarno, S.T., M.T.
2. Sekretaris Sidang : Rendyansyah, S.Kom., M.T.
3. Penguji Sidang : Dr. Ir. Bambang Tutuko, M.T.
4. Pembimbing : Prof. Dr. Ir. Siti Nurmaini, M.T.



Mengetahui,

Ketua Jurusan Sistem Komputer



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

HALAMAN PERNYATAAN

Yang bertanda tangan di bawah ini :

Nama : M. Adhitya Reski Pratama. R
NIM : 09011281722036
Judul : Pengenalan Pola Pandangan Jantung Janin menggunakan Arsitektur
Faster R-CNN

Hasil Penyecekan *Software iThenticate/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.



Indralaya, Juli 2021



M. Adhitya Reski Pratama. R
NIM. 09011281722036

KATA PENGANTAR

Assalamu'alaykum Wr.Wb.

Ungkapan syukur penulis panjatkan kepada Allah SWT, atas limpahan nikmat, rahmat, serta hidayah-Nya sehingga penulis dapat menyelesaikan penyusunan tugas akhir ini yang berjudul “Pengenalan Pola Pandangan Jantung Janin Menggunakan Arsitektur *Faster R-CNN*”.

Dalam laporan ini penulis menjelaskan proses bagaimana cara mengenali pola cara pandang jantung janin yang disertai data-data dan hasil yang diperoleh. Penulis berharap laporan ini bermanfaat bagi banyak pihak, serta menjadi salah satu sumber bacaan atau referensi bagi akademisi dan peneliti lain yang sedang menekuni bidang citra.

Penulis mendapatkan ide, saran dan bantuan dalam menyusun laporan ini dari banyak pihak. Maka dari itu, dalam kesempatan ini penulis ucapkan rasa syukur kepada Allah SWT dan rasa terimakasih penulis kepada semua pihak yang terhormat, antara lain:

1. Kedua orang tua serta keluarga yang selalu mendoakan, nasehat, dukungan moril, dan materil.
2. Yth, bapak Jaidan Jauhari, S.Pd., M.T., selaku Dekan Fakultas Ilmu Komputer Universitas Sriwijaya.
3. Yth, bapak Dr. Ir. Sukemi, M.T., selaku Ketua Jurusan Sistem Komputer Fakultas Ilmu Komputer Universitas Sriwijaya, dan selaku Pembimbing Akademik Jurusan Sistem Komputer
4. Yth, ibu Prof. Dr. Ir. Siti Nurmaini, M.T., selaku pembimbing tugas akhir yang selalu meluangkan waktu memberikan bimbingan, arahan, dan dukungan dalam menyelesaikan Proposal Tugas Akhir.

5. Kepada teman-teman tim penelitian ISysRG khususnya bidang citra yang telah mendukung penulis dalam menyelesaikan tugas akhir.
6. Kak Naufal, mba Ade, dan mba Annisa sebagai mentor dalam menyelesaikan tugas akhir.
7. Jo, Irvan, Sultan, dan Iqbal sebagai teman yang telah banyak membantu dan menemani penulis dari awal perkuliahan, hingga saat ini.
8. Adityo Aji Pambudi, teman SMA yang telah membantu menyelesaikan pembuatan aplikasi, sehingga penulis bisa fokus menyelesaikan tugas akhir.
9. Kak Bima, dan Kak Irawan sebagai kakak tingkat yang memberikan data penelitian, pengetahuan dalam menyelesaikan Proposal Tugas Akhir.
10. Aziz Mulki Rafani, Asri Safmi sebagai teman satu kelas yang selalu membantu mengatasi kendala laptop dalam menyelesaikan tugas akhir.
11. Qiliq, Luthfi, dan Ardi sebagai partner kuliah yang rela membuang waktunya menunggu penulis selama perkuliahan.
12. Kepada teman satu angkatan, seperjuangan Sistem Komputer 2017 Reguler yang telah mendukung, membersamai selama kuliah di Sistem Komputer.
13. Rezeki Ananda yang tak pernah bosan memberikan dukungan, nasihat, serta saran.

Penulis menyadari bahwa tugas akhir ini jauh dari kata sempurna. Untuk itu penulis menerima sepenuhnya kritik dan saran yang bersifat membangun.

Wassalamu'alaykum Wr. Wb.

Palembang, Juli 2021



M. Adhitya Reski Pratama. R

PATTERN RECOGNITION OF FETAL HEART SCREENING VIEWS USING FASTER R-CNN ARCHITECTURE

M. ADHITYA RESKI PRATAMA. R (09011281722036)

Computer Engineering Department, Computer Science Faculty, Sriwijaya University

Email: m.adhityareskip@outlook.com

Abstract



Clinicians need the capabilities of deep learning to minimize healthcare costs, diagnose patient diseases, increase the chance to recover, and save many lives. Deep learning has also proven to optimize the accuracy of diagnoses. The literatures of fetal heart are still limited due to heart screening views data can't be easily access by everyone. This study has explored four fetal heart screening views by ultrasonography videos. It consists of four chamber view, left ventricular outflow tract, right ventricular outflow tract, and three vessel and thrachea view. For pre-processing data, the videos have converted to frames. Also, the frames have annotated and augmented in training data. Faster R-CNN have implemented to get more accuracy and better optimization. This study used VGG16 and ResNet50 as backbone or feature extractors and pre-trained model from PASCAL VOC 2007. As the results, VGG16 outperformed ResNet50 model. Faster R-CNN with VGG16 achieves AP (average precision) for four chamber view 86.09%, left ventricular outflow tract 86.87%, right ventricular outflow tract 96.35%, and three vessel and trachea view 89.46%. For unseen data, the model gets mAP (mean average precision) 89.69%.

Keywords: *Pattern Recognition, Object Detection, Pre-Trained Model, VGG16, ResNet50, Medical Imaging, Ultrasonography, Faster R-CNN, Fetal Heart, Augmentation, Fetal Heart Screening Views.*

Acknowledged By,

The Head of Computer Systems Department

Final Project Advisor



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



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

PENGENALAN POLA PANDANGAN JANTUNG JANIN MENGUNAKAN ARSITEKTUR *FASTER R-CNN*

M. ADHITYA RESKI PRATAMA. R (09011281722036)

Jurusan Sistem Komputer, Fakultas Ilmu Komputer, Universitas Sriwijaya
Email: m.adhityareskip@outlook.com

Abstrak

Tenaga kesehatan membutuhkan kemampuan yang dimiliki *deep learning* agar meminimalisir tarif pengobatan, mendapatkan wawasan baru dari kasus yang diderita pasien, memperbesar kemungkinan kesembuhan, dan membantu orang banyak. Selain itu, dalam mendiagnosis penyakit yang diderita, *deep learning* telah terbukti dapat mengoptimalkan akurasi diagnosis oleh tenaga kesehatan. Serta, otomatisasi juga menjadi kelebihan lain yang dimiliki *deep learning*. Penelitian yang berkaitan dengan jantung janin belum umum dilakukan karena data citra medis jantung janin sedikit sekali untuk diakses orang banyak. Data yang digunakan merupakan video ultrasonografi jantung janin. Video ultrasonografi yang digunakan antara lain cara pandang *four chamber view*, *left ventricular outflow tract*, *right ventricular outflow tract*, dan *three vessel and trachea view*. Data tersebut dikonversi menjadi frame, anotasi, dan augmentasi data sebelum digunakan. Deteksi objek dua level seperti *Faster R-CNN* memiliki akurasi lebih unggul dan mudah untuk dioptimalkan. Ekstraksi fitur menggunakan VGG16 dan ResNet50. Kedua model VGG16 dan ResNet50 menggunakan model *pre-trained* PASCAL VOC 2007. Pada kasus penelitian yang dilakukan, model yang menggunakan VGG16 lebih baik dibanding ResNet50. Model *Faster R-CNN* VGG16 memperoleh AP *four chamber view* 86.09%, *left ventricular outflow tract* 86.87%, *right ventricular outflow tract* 96.35%, dan *three vessel and trachea view* 89.46%. Model tersebut memperoleh mAP 89.69% pada data *unseen*.

Kata Kunci: Pengenalan Pola, Deteksi Objek, *Pre-Trained Model*, VGG16, ResNet50, Citra Medis, Ultrasonografi, *Faster R-CNN*, Jantung Janin, Augmentasi Data, *Fetal Heart Screening Views*.


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

	Halaman
HALAMAN PENGESAHAN	ii
HALAMAN PERSETUJUAN	iii
HALAMAN PERNYATAAN	iv
KATA PENGANTAR	v
ABSTRACT	vii
ABSTRAK	viii
DAFTAR ISI	ix
DAFTAR GAMBAR	xiv
DAFTAR TABEL	xxi
DAFTAR LAMPIRAN	xxiii
BAB I PENDAHULUAN	1
1.1. Latar Belakang.....	1
1.2. Tujuan dan Manfaat Penelitian.....	3
1.2.1. Tujuan Penelitian	3
1.2.2. Manfaat Penelitian	3
1.3. Perumusan dan Batasan Masalah Penelitian	4
1.3.1. Perumusan Masalah Penelitian	4
1.3.2. Batasan Masalah.....	4
1.4. Sistematika Penulisan.....	4
BAB II TINJAUAN PUSTAKA	6
2.1. Jantung Janin	6
2.2. Ultrasonografi Janin	8

2.3.	<i>Artificial Intelligence</i>	10
2.4.	Pengenalan Pola.....	11
2.5.	<i>Deep Learning</i>	14
2.6.	Augmentasi.....	17
2.7.	<i>Transfer Learning</i>	18
2.8.	<i>Faster R-CNN</i>	19
2.9.	MAP (<i>Mean Avarage Precision</i>).....	20
BAB III METODOLOGI PENELITIAN		22
3.1.	Kerangka Kerja Penelitian.....	22
3.2.	Studi Literatur.....	22
3.3.	Pengambilan Data.....	22
3.4.	Persiapan Data	23
3.4.1.	Konversi Video menjadi Frame	23
3.4.2.	Anotasi Data.....	30
3.4.3.	Membagi Data Latih dan Data Uji.....	31
3.4.4.	Augmentasi Data Latih	33
3.5.	Jumlah Data	39
3.6.	<i>Faster R-CNN</i>	40
3.6.1.	Ekstraksi Fitur	44
3.6.2.	<i>RPN (Region Proposal Network)</i>	46
3.6.3.	<i>NMS (Non-max suppression)</i>	49
3.6.4.	RoI Pooling	51
3.6.5.	<i>Epoch</i>	52
3.6.6.	<i>Learning Rate</i>	52
3.6.7.	<i>Optimizer</i>	52
3.6.8.	Fungsi <i>Loss</i>	54

3.6.9.	Proses Pelatihan, Validasi, dan Pengujian	54
3.6.10.	Proses Validasi	55
3.6.11.	Analisa Hasil	56
3.6.12.	Kesimpulan.....	56
BAB IV HASIL DAN PEMBAHASAN		57
4.1.	Kebutuhan Pengujian Sistem.....	57
4.1.1.	Kasus Uji 3 Pandangan	57
4.1.2.	Kasus Uji 4 Pandangan Data <i>Unseen</i> Inter Pasien <i>Transfer Learning</i> 58	
4.1.3.	Kasus Uji 4 Pandangan Data <i>Unseen</i> Inter Pasien Setiap Kelas Seimbang <i>Transfer Learning</i>	59
4.2.	Pengujian Sistem Kasus Uji 3 Pandangan <i>Faster R-CNN</i>	59
4.2.1.	Model <i>Faster R-CNN</i> VGG16 SGD MAE 0.001.....	59
4.2.2.	Model <i>Faster R-CNN</i> ResNet50 SGD MAE 0.001	61
4.2.3.	Contoh Frame Hasil Deteksi Kasus Uji 3 Pandangan.....	63
4.2.4.	Contoh Frame Salah Deteksi Kasus Uji 3 Pandangan	65
4.3.	Pengujian Sistem <i>Faster R-CNN</i> Kasus Uji 4 Pandangan Data <i>Unseen</i> Inter Pasien <i>Transfer Learning</i>	67
4.3.1.	Model VGG16 Adam 0.001 MAE <i>Transfer Learning</i>	68
4.3.2.	Model VGG16 Adam 0.0001 MAE <i>Transfer Learning</i>	69
4.3.3.	Model VGG16 Adam 0.00001 MAE <i>Transfer Learning</i>	70
4.3.4.	Model VGG16 Adam 0.001 MSE <i>Transfer Learning</i>	71
4.3.5.	Model VGG16 Adam 0.0001 MSE <i>Transfer Learning</i>	72
4.3.6.	Model VGG16 Adam 0.00001 MSE <i>Transfer Learning</i>	73
4.3.7.	Model VGG16 RMSProp 0.001 MAE <i>Transfer Learning</i>	74
4.3.8.	Model VGG16 RMSProp 0.0001 MAE <i>Transfer Learning</i>	75
4.3.9.	Model VGG16 RMSProp 0.00001 MAE <i>Transfer Learning</i>	76

4.3.10.	Model VGG16 RMSProp 0.001 MSE <i>Transfer Learning</i>	77
4.3.11.	Model VGG16 RMSProp 0.0001 MSE <i>Transfer Learning</i>	78
4.3.12.	Model VGG16 RMSProp 0.00001 MSE <i>Transfer Learning</i>	79
4.3.13.	Model VGG16 SGD 0.001 MAE <i>Transfer Learning</i>	80
4.3.14.	Model VGG16 SGD 0.0001 MAE <i>Transfer Learning</i>	81
4.3.15.	Model VGG16 SGD 0.00001 MAE <i>Transfer Learning</i>	82
4.3.16.	Model VGG16 SGD 0.001 MSE <i>Transfer Learning</i>	83
4.3.17.	Model VGG16 SGD 0.0001 MSE <i>Transfer Learning</i>	84
4.3.18.	Model VGG16 SGD 0.00001 MSE <i>Transfer Learning</i>	85
4.3.19.	Model ResNet50 Adam 0.001 MAE <i>Transfer Learning</i>	86
4.3.20.	Model ResNet50 Adam 0.0001 MAE <i>Transfer Learning</i>	87
4.3.21.	Model ResNet50 Adam 0.00001 MAE <i>Transfer Learning</i>	88
4.3.22.	Model ResNet50 Adam 0.001 MSE <i>Transfer Learning</i>	89
4.3.23.	Model ResNet50 Adam 0.0001 MSE <i>Transfer Learning</i>	90
4.3.24.	Model ResNet50 Adam 0.00001 MSE <i>Transfer Learning</i>	91
4.3.25.	Model ResNet50 RMSProp 0.001 MAE <i>Transfer Learning</i>	92
4.3.26.	Model ResNet50 RMSProp 0.0001 MAE <i>Transfer Learning</i>	93
4.3.27.	Model ResNet50 RMSProp 0.00001 MAE <i>Transfer Learning</i> ..	94
4.3.28.	Model ResNet50 RMSProp 0.001 MSE <i>Transfer Learning</i>	95
4.3.29.	Model ResNet50 RMSProp 0.0001 MSE <i>Transfer Learning</i>	95
4.3.30.	Model ResNet50 RMSProp 0.00001 MSE <i>Transfer Learning</i> ...	97
4.3.31.	Model ResNet50 SGD 0.001 MAE <i>Transfer Learning</i>	98
4.3.32.	Model ResNet50 SGD 0.0001 MAE <i>Transfer Learning</i>	99
4.3.33.	Model ResNet50 SGD 0.00001 MAE <i>Transfer Learning</i>	100
4.3.34.	Model ResNet50 SGD 0.001 MSE <i>Transfer Learning</i>	101
4.3.35.	Model ResNet50 SGD 0.0001 MSE <i>Transfer Learning</i>	102

4.3.36.	Model ResNet50 SGD 0.00001 MSE <i>Transfer Learning</i>	103
4.3.37.	Contoh Frame Hasil Deteksi Kasus Data <i>Unseen</i> Inter Pasien 4 Pandangan	104
4.4.	Pengujian Sistem <i>Faster R-CNN</i> Kasus Uji 4 Pandangan Seimbang Setiap Kelas Data <i>Unseen transfer learning</i>	111
4.4.1.	Model <i>Faster R-CNN</i> VGG16 Adam MAE 0.0001 Kasus Ketiga	111
4.4.2.	Model <i>Faster R-CNN</i> VGG16 Adam MAE 0.00001 Kasus Ketiga	112
4.4.3.	Model <i>Faster R-CNN</i> VGG16 Adam MSE 0.0001 Kasus Ketiga	113
4.4.4.	Model <i>Faster R-CNN</i> VGG16 RMSProp MAE 0.00001 Kasus Ketiga	114
4.4.5.	Model <i>Faster R-CNN</i> ResNet50 Adam MAE 0.0001 Kasus Ketiga	115
4.4.6.	Model <i>Faster R-CNN</i> ResNet50 Adam MAE 0.00001 Kasus Ketiga	116
4.4.7.	Model <i>Faster R-CNN</i> ResNet50 Adam MSE 0.0001	117
4.4.8.	Model <i>Faster R-CNN</i> ResNet50 RMSProp MAE 0.00001	118
4.4.9.	Contoh Frame Hasil Deteksi Kasus Ketiga 4 Pandangan Data <i>Unseen</i> Inter Pasien <i>Transfer Learning</i>	119
4.4.10.	Contoh Frame Salah Deteksi Kasus Ketiga 4 Pandangan Data <i>Unseen</i> Inter Paasein <i>Transfer Learning</i>	120
4.5.	Analisa.....	124
BAB V KESIMPULAN.....		128
5.1.	Kesimpulan.....	128
5.2.	Saran.....	129
DAFTAR PUSTAKA		130

DAFTAR GAMBAR

Gambar 2.1 Anatomi jantung janin[26].....	6
Gambar 2.2 Citra cara pandang jantung janin[6]	8
Gambar 2.3 Lingkup <i>artificial intelligence</i> , <i>machine learning</i> , dan <i>deep learning</i> [36]	10
Gambar 2.4 Arsitektur Umum CNN[45].....	15
Gambar 2.5 Konvolusi menghasilkan <i>feature map</i> [45].....	15
Gambar 2.6 Proses prosedur <i>max pooling</i> [45]	16
Gambar 3.1 Alur penelitian	22
Gambar 3.2 Data video yang terkumpul.....	23
Gambar 3.3 Hasil pemotongan video menjadi frame	24
Gambar 3.4 Anotasi frame menggunakan labeling dan hasil anotasi format .xml	30
Gambar 3.5 Perbedaan sebelum dan sesudah augmentasi <i>flip horizontal</i>	34
Gambar 3.6 Perbedaan sebelum dan sesudah augmentasi <i>scaling</i>	35
Gambar 3.7 Perbedaan sebelum dan sesudah augmentasi <i>translation</i>	36
Gambar 3.8 Perbedaan sebelum dan sesudah augmentasi <i>rotation</i>	37
Gambar 3.9 Perbedaan sebelum dan sesudah augmentasi <i>shearing</i>	38
Gambar 3.10 Grafik perbandingan jumlah data dan hasil akurasi pada kasus klasifikasi[70].....	39
Gambar 3.11 Arsitektur RPN <i>Faster R-CNN</i> [11]	40
Gambar 3.12 Arsitektur VGG16[71].....	42
Gambar 3.13 Arsitektur ResNet50[72].....	43
Gambar 3.14 Contoh filter dengan ukuran 3x3 dan 7x7	45
Gambar 3.15 Contoh ekstraksi fitur lapisan konvolusi	46

Gambar 3.16 Skala dan rasio <i>anchor box</i> RPN[11]	47
Gambar 3.17 Perbedaan <i>threshold</i> NMS 0.5 dan 0.7 pada hasil deteksi[75]	50
Gambar 3.18 Operasi <i>max pooling</i> <i>Faster R-CNN</i> [11]	51
Gambar 3.19 Perhitungan performa model	55
Gambar 4.1 Grafik model <i>loss</i> VGG16 dihasilkan RPN kasus 3 pandangan.....	60
Gambar 4.2 Grafik model <i>loss</i> VGG16 dihasilkan <i>classifier</i> kasus 3 pandangan.....	60
Gambar 4.3 Grafik model <i>loss</i> ResNet50 dihasilkan RPN kasus 3 pandangan ..	61
Gambar 4.4 Grafik model <i>loss</i> ResNet50 dihasilkan <i>classifier</i> kasus 3 pandangan	61
Gambar 4.5 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> Adam MAE 0.001 dihasilkan RPN	68
Gambar 4.6 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> Adam MAE 0.001 dihasilkan <i>classifier</i>	68
Gambar 4.7 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> Adam MAE 0.0001 dihasilkan RPN	69
Gambar 4.8 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> Adam MAE 0.0001 dihasilkan <i>classifier</i>	69
Gambar 4.9 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> Adam MAE 0.00001 MAE dihasilkan RPN.....	70
Gambar 4.10 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> Adam MAE 0.00001 dihasilkan <i>classifier</i>	70
Gambar 4.11 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> Adam MSE 0.001 dihasilkan RPN	71
Gambar 4.12 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> Adam MSE 0.001 dihasilkan <i>classifier</i>	71
Gambar 4.13 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> Adam MSE 0.0001 dihasilkan RPN	72
Gambar 4.14 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> Adam MSE 0.0001 dihasilkan <i>classifier</i>	72
Gambar 4.15 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> Adam MSE 0.00001 dihasilkan RPN	73

Gambar 4.16 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> Adam MSE 0.00001 dihasilkan <i>classifier</i>	73
Gambar 4.17 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> RMSProp MAE 0.001 dihasilkan RPN	74
Gambar 4.18 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> RMSProp MAE 0.001 dihasilkan <i>classifier</i>	74
Gambar 4.19 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> RMSProp MAE 0.0001 dihasilkan RPN	75
Gambar 4.20 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> RMSProp MAE 0.0001 dihasilkan <i>classifier</i>	75
Gambar 4.21 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> RMSProp MAE 0.00001 dihasilkan RPN.....	76
Gambar 4.22 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> RMSProp MAE 0.00001 dihasilkan <i>classifier</i>	76
Gambar 4.23 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> RMSProp MSE 0.001 dihasilkan RPN	77
Gambar 4.24 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> RMSProp MSE 0.001 dihasilkan <i>classifier</i>	77
Gambar 4.25 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> RMSProp MSE 0.0001 dihasilkan <i>classifier</i>	78
Gambar 4.26 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> RMSProp MSE 0.0001 dihasilkan <i>classifier</i>	78
Gambar 4.27 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> RMSProp MSE 0.00001 dihasilkan RPN	79
Gambar 4.28 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> RMSProp MSE 0.00001 dihasilkan <i>classifier</i>	79
Gambar 4.29 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> SGD MAE 0.001 dihasilkan RPN	80
Gambar 4.30 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> SGD MAE 0.001 dihasilkan <i>classifier</i>	80
Gambar 4.31 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> SGD MAE 0.0001 dihasilkan RPN	81
Gambar 4.32 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> SGD MAE 0.0001 dihasilkan <i>classifier</i>	81

Gambar 4.33 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> SGD MAE 0.00001 dihasilkan RPN	82
Gambar 4.34 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> SGD MAE 0.00001 dihasilkan <i>classifier</i>	82
Gambar 4.35 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> SGD MSE 0.001 dihasilkan RPN	83
Gambar 4.36 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> SGD MSE 0.001 dihasilkan <i>classifier</i>	83
Gambar 4.37 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> SGD MSE 0.0001 dihasilkan RPN	84
Gambar 4.38 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> SGD MSE 0.0001 dihasilkan <i>classifier</i>	84
Gambar 4.39 Grafik <i>loss</i> VGG16 <i>transfer learning</i> MSE 0.00001 dihasilkan RPN	85
Gambar 4.40 Grafik <i>loss</i> VGG16 <i>transfer learning</i> MSE 0.00001 dihasilkan <i>classifier</i>	85
Gambar 4.41 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> Adam MAE 0.001 dihasilkan RPN	86
Gambar 4.42 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> Adam MAE 0.001 dihasilkan <i>classifier</i>	86
Gambar 4.43 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> Adam MAE 0.0001 dihasilkan RPN	87
Gambar 4.44 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> Adam MAE 0.0001 dihasilkan <i>classifier</i>	87
Gambar 4.45 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> Adam MAE 0.00001 dihasilkan RPN	88
Gambar 4.46 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> Adam MAE 0.00001 dihasilkan <i>classifier</i>	88
Gambar 4.47 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> Adam MSE 0.001 dihasilkan RPN	89
Gambar 4.48 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> Adam MSE 0.001 dihasilkan <i>classifier</i>	89
Gambar 4.49 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> Adam MSE 0.0001 dihasilkan RPN	90

Gambar 4.50 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> Adam MSE 0.0001 dihasilkan <i>classifier</i>	90
Gambar 4.51 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> Adam MSE 0.00001 dihasilkan RPN	91
Gambar 4.52 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> Adam MSE 0.00001 dihasilkan <i>classifier</i>	91
Gambar 4.53 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> RMSProp MAE 0.001 dihasilkan RPN	92
Gambar 4.54 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> RMSProp MAE 0.001 dihasilkan <i>classifier</i>	92
Gambar 4.55 Grafik model <i>loss</i> ResNet50 RMSProp <i>transfer learning</i> MAE 0.0001 dihasilkan RPN.....	93
Gambar 4.56 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> MAE 0.0001 dihasilkan <i>classifier</i>	93
Gambar 4.57 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> RMSProp MAE 0.00001 dihasilkan RPN.....	94
Gambar 4.58 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> RMSProp MAE 0.00001 dihasilkan <i>classifier</i>	94
Grafik 4.59 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> RMSProp MSE 0.001 dihasilkan RPN	95
Gambar 4.60 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> RMSProp MSE 0.001 dihasilkan <i>classifier</i>	95
Gambar 4.61 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> RMSProp MSE 0.0001 dihasilkan RPN.....	96
Gambar 4.62 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> RMSProp MSE 0.0001 dihasilkan <i>classifier</i>	96
Gambar 4.63 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> RMSProp MSE 0.00001 dihasilkan RPN.....	97
Gambar 4.64 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> RMSProp MSE 0.00001 dihasilkan <i>classifier</i>	97
Gambar 4.65 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> SGD MAE 0.001 dihasilkan RPN	98
Gambar 4.66 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> SGD MAE 0.001 dihasilkan <i>classifier</i>	98

Gambar 4.67 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> SGD MAE 0.0001 dihasilkan RPN	99
Gambar 4.68 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> SGD MAE 0.0001 dihasilkan <i>classifier</i>	99
Gambar 4.69 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> SGD 0.00001 dihasilkan RPN	100
Gambar 4.70 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> SGD MAE 0.00001 dihasilkan <i>classifier</i>	100
Gambar 4.71 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> SGD MSE 0.001 dihasilkan RPN	101
Gambar 4.72 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> SGD MSE 0.001 dihasilkan <i>classifier</i>	101
Gambar 4.73 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> SGD MSE 0.0001 dihasilkan RPN	102
Gambar 4.75 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> SGD MSE 0.0001 dihasilkan <i>classifier</i>	102
Gambar 4.75 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> SGD MSE 0.00001 dihasilkan RPN	103
Gambar 4.76 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> SGD MSE 0.00001 dihasilkan <i>classifier</i>	103
Gambar 4.77 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> Adam MAE 0.0001 kasus ketiga dihasilkan RPN.....	111
Gambar 4.78 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> Adam MAE 0.0001 kasus ketiga dihasilkan RPN.....	111
Gambar 4.79 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> Adam MAE 0.00001 kasus ketiga dihasilkan RPN.....	112
Gambar 4.80 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> Adam MAE 0.00001 kasus ketiga dihasilkan <i>classifier</i>	112
Gambar 4.81 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> Adam MSE 0.0001 kasus ketiga dihasilkan RPN.....	113
Gambar 4.82 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> Adam MSE 0.0001 kasus ketiga dihasilkan <i>classifier</i>	113
Gambar 4.83 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> RMSProp MAE 0.00001 kasus ketiga dihasilkan RPN.....	114

Gambar 4.84 Grafik model <i>loss</i> VGG16 <i>transfer learning</i> RMSProp MAE 0.00001 kasus ketiga dihasilkan <i>classifier</i>	114
Gambar 4.85 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> Adam MAE 0.0001 kasus ketiga dihasilkan RPN	115
Gambar 4.86 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> Adam MAE 0.0001 kasus ketiga dihasilkan <i>classifier</i>	115
Gambar 4.87 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> Adam MAE 0.00001 kasus ketiga dihasilkan RPN	116
Gambar 4.88 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> Adam MAE 0.00001 kasus ketiga dihasilkan <i>classifier</i>	116
Gambar 4.89 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> Adam MSE 0.0001 kasus ketiga dihasilkan RPN	117
Gambar 4.90 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> Adam MSE 0.0001 kasus ketiga dihasilkan <i>classifier</i>	117
Gambar 4.91 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> RMSProp MAE 0.00001 kasus ketiga dihasilkan RPN	118
Gambar 4.92 Grafik model <i>loss</i> ResNet50 <i>transfer learning</i> RMSProp MAE 0.00001 kasus ketiga dihasilkan <i>classifier</i>	118
Gambar 4.93 Perbedaan objek jantung tidak buram dan buram.....	125
Gambar 4.94 Contoh cara pandang jantung janin FCV dan LVOT pada data latih	125
Gambar 4.95 Dua <i>bounding box</i> pada satu objek dengan kelas berbeda	126

DAFTAR TABEL

Tabel 3.1 Jumlah frame hasil pemotongan video kasus 3 pandangan.....	25
Tabel 3.2 Pemotongan informasi pasien di video	26
Tabel 3.3 Jumlah frame hasil pemotongan video kasus data <i>unseen</i> inter pasien 4 pandangan	28
Tabel 3.4 Jumlah frame hasil pemotongan video kasus data <i>unseen</i> inter pasien seimbang setiap kelas 4 pandangan.....	29
Tabel 3.5 Contoh hasil konversi label dan frame menjadi data latih dan data uji format .csv.....	31
Tabel 3.6 Informasi data pada kasus pertama	32
Tabel 3.7 Informasi data pada kasus kedua.....	32
Tabel 3.8 Informasi data pada kasus ketiga.....	32
Tabel 3.9 Perbandingan sebelum dan sesudah augmentasi data pada data latih kasus 4 pandangan data <i>unseen transfer learning</i>	33
Tabel 3.10 Perbandingan sebelum dan sesudah augmentasi pada data latih kasus 4 pandangan data <i>unseen</i> jumlah data setiap kelas seimbang <i>transfer learning</i>	33
Tabel 4.1 Informasi data kasus 3 pandangan.....	57
Tabel 4.2 Model <i>Faster R-CNN</i> kasus 3 pandangan	58
Tabel 4.3 Model <i>Faster R-CNN</i> kasus 4 pandangan <i>transfer learning</i>	58
Tabel 4.4 Model <i>Faster R-CNN</i> kasus 4 pandangan data <i>unseen</i> inter pasien setiap kelas seimbang <i>transfer learning</i>	59
Tabel 4.5 Hasil deteksi <i>Faster R-CNN</i> pada data uji	62
Tabel 4.6 Hasil evaluasi VGG16 dan ResNet50 kasus 3 pandangan	63
Tabel 4.7 Contoh hasil deteksi <i>Faster R-CNN</i> kasus uji 3 pandangan.....	63
Tabel 4.8 Contoh hasil salah deteksi <i>Faster R-CNN</i> kasus uji 3 pandangan	65
Tabel 4.9 Model <i>Faster R-CNN</i> kasus 4 pandangan data <i>unseen transfer learning</i>	67

Tabel 4.10 Hasil deteksi <i>Faster R-CNN</i> pada data <i>unseen</i> inter pasien 4 pandangan <i>transfer learning</i>	104
Tabel 4.11 Hasil salah deteksi pada kasus 4 pandangan data <i>unseen</i> inter pasien <i>transfer learning</i>	105
Tabel 4.12 Perbandingan model <i>Faster R-CNN</i> data <i>unseen</i> inter pasien 4 pandangan <i>transfer learning</i>	108
Tabel 4.13 Contoh hasil deteksi <i>Faster R-CNN</i> kasus ketiga 4 pandangan data <i>unseen</i> inter pasien <i>transfer learning</i>	119
Tabel 4.14 Contoh hasil salah deteksi <i>Faster R-CNN</i> kasus ketiga 4 pandangan data <i>unseen</i> inter pasien <i>transfer learning</i>	120
Tabel 4.15 Perbandingan model <i>Faster-RCNN</i> data <i>unseen</i> inter pasien <i>transfer learning</i> kasus ketiga.....	123

DAFTAR LAMPIRAN

Lampiran 1. Form Perbaikan

Lampiran 2. Cek Plagiat

BAB I

PENDAHULUAN

1.1. Latar Belakang

Kendala umum dalam bidang *computer vision* ialah salah satunya pada kasus deteksi objek, yaitu menemukan objek pada gambar yang sudah ditentukan kategorinya, seperti sepeda, manusia, kendaraan, dan hewan. *Deep learning* mampu mempelajari representasi fitur langsung yang ada pada data, juga telah terbukti menghasilkan terobosan baru pada deteksi objek[1]. Implementasi *Deep learning* telah diterapkan di sejumlah aspek. Dari sekian aspek yang menggunakan *deep learning*, satu diantaranya adalah aspek kesehatan. Tenaga kesehatan membutuhkan kemampuan yang dimiliki *deep learning* agar meminimalisir tarif pengobatan, mendapatkan wawasan baru dari kasus yang diderita pasien, memperbesar kemungkinan kesembuhan, dan membantu orang banyak [2]. Selain itu, dalam mendiagnosis penyakit yang diderita, *deep learning* telah terbukti dapat mengoptimalkan akurasi diagnosis oleh tenaga kesehatan. Serta, otomatisasi juga menjadi kelebihan lain yang dimiliki *deep learning*[3]. Namun, selain banyak kemajuan yang signifikan dari bidang deteksi objek, masih ada jarak performa antara deteksi objek kecil dan deteksi objek besar[4].

Ultrasonografi sering diaplikasikan pada aspek kesehatan menggunakan kemampuan yang dimiliki *deep learning*[2][3]. Aplikasi ultrasonografi untuk mendapatkan informasi mengenai perkembangan janin di rahim. Citra yang dihasilkan ultrasonografi dua dimensi belum sepenuhnya mampu menghasilkan informasi yang rinci. Ultrasonografi terdiri dari dua, tiga, bahkan empat dimensi. Setiap dimensi ultrasonografi terdapat kelebihan dan kekurangan, semakin tinggi dimensi yang digunakan, maka semakin mahal harga alat tersebut. Namun, ultrasonografi dua dimensi masih banyak digunakan dokter kandungan karena dianggap masih representatif dalam memeriksa kandungan. Citra yang dihasilkan

ultrasonografi dihasilkan dari sensor serta transduser memiliki intensitas rendah.[5].

Kelainan jantung diperkirakan dapat terjadi antara lima sampai enam dari seribu bayi yang lahir. Umumnya anak yang terkena, lahir dari rahim ibu yang tidak memiliki faktor risiko penyakit jantung bawaan. Data yang dirilis WHO dari menunjukkan bahwa cacat jantung merupakan penyumbang kematian bayi sebanyak empat puluh persen[6]. Bayi lahir dengan kondisi kelainan jantung bawaan adalah peristiwa yang relatif sering karena termasuk salah satu cacat lahir paling umum, hampir satu persen mempengaruhi dari semua kehamilan. Diagnosis prenatal dilakukan terbukti meningkatkan morbiditas dan mortalitas, serta berkurangnya pengeluaran terkait transportasi dan resusitasi bayi baru lahir yang kolaps. Pemeriksaan pada ibu hamil guna untuk menginformasikan pengambilan keputusan reproduksi. Keluarga dapat mencapai kesepakatan dengan merencanakan tindakan yang akan diambil, termasuk peluang adanya operasi jantung, selama beberapa bulan sebelum daripada dalam hitungan jam ketika diagnosis jantung dibuat hanya setelah melahirkan. Namun, tetap saja prediksi kualitas hidup anak dengan kelainan jantung bawaan sulit dilakukan[7]. Penelitian yang berkaitan dengan jantung janin belum umum dilakukan karena data citra medis jantung janin sedikit sekali untuk diakses orang banyak[2].

Beberapa metode dalam deteksi objek terdiri dari dua kategori deteksi objek, yaitu *region proposal* dan metode regresi atau klasifikasi. Arsitektur yang termasuk kategori *region proposal* mulai dari *R-CNN*[8], *SPP-net*[9], *Fast R-CNN*[10], *Faster R-CNN*[11], *R-FCN*[12], *FPN*[13], *Mask R-CNN*[14]. Arsitektur lain yang termasuk kategori regresi atau klasifikasi adalah *MultiBox*[15], *AttentionNet*[16], *G-CNN*[17], *YOLO*[18], *SSD*[19], *YOLOv2*[20], *DSSD*[21], hingga *DSOD*[22][23]. Perkembangan CNN memiliki kemampuan yang lebih unggul[11].

Faster R-CNN mengganti algoritma pencarian selektif di *Fast R-CNN* dengan RPN yang terbukti lebih efisien dalam memperkirakan *region proposal* menggunakan ukuran skala dan rasio. *Faster R-CNN* berhasil meningkatkan presisi dan efisiensi deteksi objek, yaitu pada data PASCAL VOC 2007, *Faster R-CNN*

memperoleh *mAP* sebesar 69.9%, lebih baik dibanding *Fast R-CNN* yang hanya memperoleh *mAP* sebesar 66.9%[24]. Deteksi objek dua level seperti *Faster R-CNN* memiliki akurasi hasil lebih unggul dan mudah untuk dioptimalkan, namun deteksi objek dua level tidak begitu cepat dan membutuhkan input yang sangat besar, karena adanya operasi *ROI pooling*[25]. *Faster R-CNN* terbukti memiliki ketepatan deteksi dan kinerja lebih unggul daripada *R-CNN* dan *Fast R-CNN*[11]. Deteksi objek satu level seperti *YOLO* mempunyai kelebihan dari sisi kecepatan. Tapi, deteksi satu level *YOLO* lemah dalam presisi, serta akurasi [24].

1.2. Tujuan dan Manfaat Penelitian

1.2.1. Tujuan Penelitian

Beberapa target penelitian yang ingin dicapai, yaitu terdiri dari:

1. Penerapan *Faster R-CNN* pada kasus cara pandang jantung janin.
2. Mendapatkan hasil deteksi dalam mengenali pola cara pandang jantung janin.
3. Analisa evaluasi model dalam mengenali pola cara pandang jantung janin menggunakan *mAP* (*mean average precision*).

1.2.2. Manfaat Penelitian

Penelitian yang dilakukan diharapkan mampu berguna bagi banyak pihak yang terdiri dari:

1. Dapat dijadikan sebagai referensi deteksi objek dalam mengenali objek lainnya.
2. Dapat dijadikan referensi dalam mengambil keputusan bagi tenaga medis seperti dokter dalam mabadakan cara pandang jantung janin ultrasonografi.

1.3. Perumusan dan Batasan Masalah Penelitian

1.3.1. Perumusan Masalah Penelitian

Adapun rumusan masalah dalam penelitian ini, antara lain sebagai berikut:

1. Bagaimana membangun model *Faster R-CNN* agar mampu mendeteksi pola cara pandang jantung janin?
2. Bagaimana *Faster R-CNN* mampu mendeteksi cara pandang jantung janin?
3. Bagaimana nilai akurasi performa *Faster R-CNN* terhadap cara pandang jantung janin?

1.3.2. Batasan Masalah

Berikut batasan masalah dalam penelitian ini, yaitu antara lain:

1. Deteksi objek menggunakan *Faster R-CNN backbone* ResNet50 dan VGG16.
2. Data yang digunakan adalah citra ultrasonografi jantung janin.
3. Penelitian dilakukan menggunakan cara pandang *Right ventricular outflow tract*, *Left ventricular outflow tract*, *Three vessel trachea view*, dan *Four chamber view*.
4. Pengukuran kinerja model *Faster R-CNN* menerapkan *mAP*.

1.4. Sistematika Penulisan

Tugas akhir yang dibuat akan menerapkan susunan penulisan. Susunan tersebut digunakan agar penulisan lebih terstruktur. Adapun susunan penulisan yang digunakan antara lain:

BAB I – PENDAHULUAN

Pada bagian ini merupakan garis besar dilakukannya penelitian, pembaca dapat menangkap informasi tujuan, manfaat, dan batasan penelitian.

BAB II – TINJAUAN PUSTAKA

Bagian selanjutnya adalah kumpulan dari berbagai sumber yang didapatkan penulis yang dijadikan sebagai referensi penelitian. Penulis mencari banyak informasi dari banyak sumber untuk menyelesaikan persoalan yang dihadapi selama penelitian berlangsung.

BAB III – METODOLOGI

Berikutnya merupakan bagian dimana penulis menjelaskan proses yang dilewati selama penelitian untuk mendapatkan hasil yang menjadi tujuan penelitian.

BAB IV – HASIL DAN PEMBAHASAN

Setelah mendapatkan hasil penelitian, pada bagian ini penulis melakukan analisa dan evaluasi hasil yang didapatkan selama penelitian, penulis juga menjelaskan hasil yang diperoleh.

BAB V – KESIMPULAN DAN SARAN

Tahap akhir yaitu berupa kesimpulan diperoleh dari penelitian, begitu juga penulis memberikan saran, serta tantangan penelitian berikutnya.

DAFTAR PUSTAKA

- [1] 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.
- [2] L. Saba *et al.*, “The present and future of deep learning in radiology,” *Eur. J. Radiol.*, vol. 114, no. February, pp. 14–24, 2019, doi: 10.1016/j.ejrad.2019.02.038.
- [3] M. P. McBee *et al.*, “Deep Learning in Radiology,” *Acad. Radiol.*, vol. 25, no. 11, pp. 1472–1480, 2018, doi: 10.1016/j.acra.2018.02.018.
- [4] M. Kisantal, Z. Wojna, J. Murawski, J. Naruniec, and K. Cho, “Augmentation for small object detection,” vol. 2017, pp. 119–133, 2019, doi: 10.5121/csit.2019.91713.
- [5] M. Khairudin and D. Irmawati, “Comparison methods of edge detection for USG images,” *Proc. - 2016 3rd Int. Conf. Inf. Technol. Comput. Electr. Eng. ICITACEE 2016*, pp. 85–88, 2017, doi: 10.1109/ICITACEE.2016.7892416.
- [6] L. E. Hunter and A. N. Seale, “Educational series in congenital heart disease: Prenatal diagnosis of congenital heart disease,” *Echo Res. Pract.*, vol. 5, no. 3, pp. R81–R100, 2018, doi: 10.1530/ERP-18-0027.
- [7] H. M. Gardiner, “Advances in fetal echocardiography,” *Semin. Fetal Neonatal Med.*, vol. 23, no. 2, pp. 112–118, 2018, doi: 10.1016/j.siny.2017.11.006.
- [8] R. Girshick, J. Donahue, T. Darrell, and J. Malik, “Rich feature hierarchies for accurate object detection and semantic segmentation,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, pp. 580–587, 2014,

doi: 10.1109/CVPR.2014.81.

- [9] K. He, X. Zhang, S. Ren, and J. Sun, “Spatial pyramid pooling in deep convolutional networks for visual recognition,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 8691 LNCS, no. PART 3, pp. 346–361, 2014, doi: 10.1007/978-3-319-10578-9_23.
- [10] R. Girshick, “Fast R-CNN,” *Proc. IEEE Int. Conf. Comput. Vis.*, vol. 2015 Inter, pp. 1440–1448, 2015, doi: 10.1109/ICCV.2015.169.
- [11] S. Ren, K. He, R. Girshick, and J. Sun, “Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 39, no. 6, pp. 1137–1149, 2017, doi: 10.1109/TPAMI.2016.2577031.
- [12] J. Dai, Y. Li, K. He, and J. Sun, “R-FCN: Object detection via region-based fully convolutional networks,” *Adv. Neural Inf. Process. Syst.*, pp. 379–387, 2016.
- [13] T.-Y. Lin, P. Dollar, R. Girshick, K. He, B. Hariharan, and S. Belongie, “Feature pyramid network for object detection,” in *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*, 2017, vol. 1, pp. 936–944, doi: 10.1109/CVPR.2017.106.
- [14] K. He, G. Gkioxari, P. Dollár, and R. Girshick, “Mask R-CNN,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 42, no. 2, pp. 386–397, 2020, doi: 10.1109/TPAMI.2018.2844175.
- [15] D. Erhan, C. Szegedy, A. Toshev, and D. Anguelov, “Scalable object detection using deep neural networks,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, pp. 2155–2162, 2014, doi: 10.1109/CVPR.2014.276.
- [16] D. Yoo, S. Park, J. Y. Lee, A. S. Paek, and I. S. Kweon, “Attentionnet: Aggregating weak directions for accurate object detection,” *Proc. IEEE Int.*

- Conf. Comput. Vis.*, vol. 2015 Inter, pp. 2659–2667, 2015, doi: 10.1109/ICCV.2015.305.
- [17] M. Najibi, M. Rastegari, and L. S. Davis, “G-CNN: An Iterative Grid Based Object Detector,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2016-Decem, pp. 2369–2377, 2016, doi: 10.1109/CVPR.2016.260.
- [18] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, “You only look once: Unified, real-time object detection,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2016-Decem, pp. 779–788, 2016, doi: 10.1109/CVPR.2016.91.
- [19] W. Liu *et al.*, “SSD: Single shot multibox detector,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 9905 LNCS, pp. 21–37, 2016, doi: 10.1007/978-3-319-46448-0_2.
- [20] J. Redmon and A. Farhadi, “YOLO9000: Better, faster, stronger,” *Proc. - 30th IEEE Conf. Comput. Vis. Pattern Recognition, CVPR 2017*, vol. 2017-Janua, pp. 6517–6525, 2017, doi: 10.1109/CVPR.2017.690.
- [21] C.-Y. Fu, W. Liu, A. Ranga, A. Tyagi, and A. C. Berg, “DSSD : Deconvolutional Single Shot Detector,” 2017, [Online]. Available: <http://arxiv.org/abs/1701.06659>.
- [22] Z. Shen, Z. Liu, J. Li, Y. G. Jiang, Y. Chen, and X. Xue, “DSOD: Learning Deeply Supervised Object Detectors from Scratch,” *Proc. IEEE Int. Conf. Comput. Vis.*, vol. 2017-Octob, pp. 1937–1945, 2017, doi: 10.1109/ICCV.2017.212.
- [23] Z. Q. Zhao, P. Zheng, S. T. Xu, and X. Wu, “Object Detection with Deep Learning: A Review,” *IEEE Trans. Neural Networks Learn. Syst.*, vol. 30, no. 11, pp. 3212–3232, 2019, doi: 10.1109/TNNLS.2018.2876865.
- [24] L. Jiao *et al.*, “A Survey of Deep Learning-Based Object Detection,” *IEEE Access*, vol. 7, no. 3, pp. 128837–128868, 2019, doi:

10.1109/access.2019.2939201.


- [25] B. Cheng, Y. Wei, H. Shi, R. Feris, J. Xiong, and T. Huang, “Revisiting RCNN: On awakening the classification power of faster RCNN,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 11219 LNCS, pp. 473–490, 2018, doi: 10.1007/978-3-030-01267-0_28.
- [26] J. G. Stinstra, *The Reliability of the Fetal Magnetocardiogram*. Enschede: Universiteit Twente, 2001.
- [27] R. Sameni, “Extraction of Fetal Cardiac Signals from an Array of Maternal Abdominal Recordings,” *Trait. du Signal*, vol. onvol, no. July, pp. 42no1pp21–28, 2008, doi: 10.13140/RG.2.2.14830.41285.
- [28] A. Quarteroni, T. Lassila, S. Rossi, and R. Ruiz-Baier, “Integrated Heart—Coupling multiscale and multiphysics models for the simulation of the cardiac function,” *Comput. Methods Appl. Mech. Eng.*, vol. 314, pp. 345–407, 2017, doi: 10.1016/j.cma.2016.05.031.
- [29] O. Bergmann *et al.*, “Evidence for cardiomyocyte renewal in humans,” *Science (80-.)*, vol. 324, no. 5923, pp. 98–102, 2009, doi: 10.1126/science.1164680.
- [30] G. Buckberg, N. Nanda, C. Nguyen, and M. Kocica, “What Is the Heart? Anatomy, Function, Pathophysiology, and Misconceptions,” *J. Cardiovasc. Dev. Dis.*, vol. 5, no. 2, p. 33, 2018, doi: 10.3390/jcdd5020033.
- [31] X. Zeng, L. Wen, B. Liu, and X. Qi, “Deep learning for ultrasound image caption generation based on object detection,” *Neurocomputing*, no. xxxx, 2019, doi: 10.1016/j.neucom.2018.11.114.
- [32] S. Liu *et al.*, “Deep Learning in Medical Ultrasound Analysis: A Review,” *Engineering*, vol. 5, no. 2, pp. 261–275, 2019, doi: 10.1016/j.eng.2018.11.020.

- [33] M. Wiechec, A. Knafel, and A. Nocun, “Prenatal detection of congenital heart defects at the 11- To 13-week scan using a simple color doppler protocol including the 4-chamber and 3-vessel and trachea views,” *J. Ultrasound Med.*, vol. 34, no. 4, pp. 585–594, 2015, doi: 10.7863/ultra.34.4.585.
- [34] L. Wu, J. Z. Cheng, S. Li, B. Lei, T. Wang, and D. Ni, “FUIQA: Fetal ultrasound image quality assessment with deep convolutional networks,” *IEEE Trans. Cybern.*, vol. 47, no. 5, pp. 1336–1349, 2017, doi: 10.1109/TCYB.2017.2671898.
- [35] A. Weissmann-Brenner, D. H. Pretorius, R. Achiron, and L. Gindes, “Fetal echocardiography: The four-chamber view, the outflow tracts, and the contribution of the cardiac arches,” *Ultrasound Clin.*, vol. 7, no. 1, pp. 1–13, 2012, doi: 10.1016/j.cult.2011.08.005.
- [36] K. Kusunose, A. Haga, T. Abe, and M. Sata, “Utilization of artificial intelligence in echocardiography,” *Circ. J.*, vol. 83, no. 8, pp. 1623–1629, 2019, doi: 10.1253/circj.CJ-19-0420.
- [37] P. Hamet and J. Tremblay, “Artificial intelligence in medicine,” *Metabolism.*, vol. 69, pp. S36–S40, 2017, doi: 10.1016/j.metabol.2017.01.011.
- [38] M. Alsharqi, W. J. Woodward, J. A. Mumith, D. C. Markham, R. Upton, and P. Leeson, “Artificial intelligence and echocardiography,” *Echo Res. Pract.*, pp. R115–R125, 2018, doi: 10.1530/erp-18-0056.
- [39] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. The MIT Press, 2016.
- [40] S. R. and P. Norvig, *Artificial Intelligence A Modern Approach 4th Ed.* Pearson, 2020.
- [41] S. Theodoridis and K. Koutroumbas, *Pattern Recognition 4th Edition*, 4th ed. Academic Press, 2009.

- [42] G. C. Rafael and W. E. Richard, *Digital image processing*, 4th ed. New York: Pearson, 2018.
- [43] J. Lee *et al.*, “Deep Learning in Medical Imaging: General Overview,” vol. 18, no. 4, pp. 570–584, 2017.
- [44] K. W. Johnson *et al.*, “Artificial Intelligence in Cardiology,” *J. Am. Coll. Cardiol.*, vol. 71, no. 23, pp. 2668–2679, 2018, doi: 10.1016/j.jacc.2018.03.521.
- [45] N. Aloysius and M. Geetha, “A review on deep convolutional neural networks,” *Proc. 2017 IEEE Int. Conf. Commun. Signal Process. ICCSP 2017*, vol. 2018-Janua, pp. 588–592, 2018, doi: 10.1109/ICCSP.2017.8286426.
- [46] M. Ozeki and T. Okatani, “Understanding convolutional neural networks in terms of category-level attributes,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 9004, pp. 362–375, 2015, doi: 10.1007/978-3-319-16808-1_25.
- [47] L. Perez and J. Wang, “The Effectiveness of Data Augmentation in Image Classification using Deep Learning,” 2017, [Online]. Available: <http://arxiv.org/abs/1712.04621>.
- [48] C. Shorten and T. M. Khoshgoftaar, “A survey on Image Data Augmentation for Deep Learning,” *J. Big Data*, vol. 6, no. 1, 2019, doi: 10.1186/s40537-019-0197-0.
- [49] B. Zoph, E. D. Cubuk, G. Ghiasi, T. Y. Lin, J. Shlens, and Q. V. Le, “Learning Data Augmentation Strategies for Object Detection,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 12372 LNCS, pp. 566–583, 2020, doi: 10.1007/978-3-030-58583-9_34.
- [50] S. J. Torrey Lisa, “Transfer Learning,” *Data Classif. Algorithms Appl.*, pp. 657–665, 2014, doi: 10.1201/b17320.

- [51] J. Talukdar, S. Gupta, P. S. Rajpura, and R. S. Hegde, "Transfer Learning for Object Detection using State-of-the-Art Deep Neural Networks," *2018 5th Int. Conf. Signal Process. Integr. Networks, SPIN 2018*, pp. 78–83, 2018, doi: 10.1109/SPIN.2018.8474198.
- [52] A. S. Razavian, H. Azizpour, J. Sullivan, and S. Carlsson, "CNN features off-the-shelf: An astounding baseline for recognition," *IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit. Work.*, pp. 512–519, 2014, doi: 10.1109/CVPRW.2014.131.
- [53] A. B. Yandex and V. Lempitsky, "Aggregating local deep features for image retrieval," *Proc. IEEE Int. Conf. Comput. Vis.*, vol. 2015 Inter, pp. 1269–1277, 2015, doi: 10.1109/ICCV.2015.150.
- [54] R. Girshick, J. Donahue, T. Darrell, and J. Malik, "Region-Based Convolutional Networks for Accurate Object Detection and Segmentation," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 38, no. 1, pp. 142–158, 2016, doi: 10.1109/TPAMI.2015.2437384.
- [55] H. N. T. K. Kaldera, S. R. Gunasekara, and M. B. Dissanayake, "Brain tumor Classification and Segmentation using Faster R-CNN," *2019 Adv. Sci. Eng. Technol. Int. Conf. ASET 2019*, no. March, 2019, doi: 10.1109/ICASET.2019.8714263.
- [56] H. Jiang and E. Learned-Miller, "Face Detection with the Faster R-CNN," in *2017 12th IEEE International Conference on Automatic Face & Gesture Recognition (FG 2017)*, 2017, pp. 650–657, doi: 10.1109/FG.2017.82.
- [57] Z. Huang, M. Fu, K. Ni, H. Sun, and S. Sun, *Recognition of vehicle-logo based on faster-RCNN*, vol. 494. Springer Singapore, 2019.
- [58] E. M., V.-G. L., W. C. K. I., W. J., and Z. A., "The Pascal Visual Object Classes (VOC) Challenge," *Int. J. Comput. Vis.*, vol. 88, no. 2, pp. 303–338, 2010.
- [59] Y. Umar, Hanafi, S. Mardi, Nugroho, Susiki, and R. F. Rachmadi, "Deteksi

Penggunaan Helm Pada Pengendara Bermotor Berbasis Deep Learning,” 2020.

- [60] D. M. El-Feky and D. Y. et al Weerakkody, “Four chamber cardiac view (fetal) | Radiology Reference Article | Radiopaedia.org,” 2017.
<https://radiopaedia.org/articles/four-chamber-cardiac-view-fetal?lang=us> (accessed Dec. 31, 2020).
- [61] D. M. El-feky and D. M. et al A. Morgan, “Left ventricular outflow tract view (fetal echocardiogram) | Radiology Reference Article | Radiopaedia.org,” 2021. <https://radiopaedia.org/articles/left-ventricular-outflow-tract-view-fetal-echocardiogram?lang=us> (accessed Dec. 31, 2020).
- [62] D. M. El-Feky and D. Y. et al Weerakkody, “Three vessel and trachea view | Radiology Reference Article | Radiopaedia.org,” 2021.
<https://radiopaedia.org/articles/three-vessel-and-trachea-view?lang=us> (accessed Dec. 31, 2020).
- [63] D. M. El-Feky and D. M. et al A. Morgan, “Right ventricular outflow tract view (fetal echocardiogram) | Radiology Reference Article | Radiopaedia.org,” 2020. <https://radiopaedia.org/articles/right-ventricular-outflow-tract-view-fetal-echocardiogram?lang=us> (accessed Jun. 24, 2021).
- [64] Intersocietal Accreditaion Commision, “Fetal Echocardiography: Protocol and Technique - YouTube,” 2020.
<https://www.youtube.com/watch?v=2qfGzNh2dR4> (accessed Jun. 24, 2021).
- [65] Tzutalin, “GitHub - tzutalin/labelImg:  LabelImg is a graphical image annotation tool and label object bounding boxes in images,” 2017.
<https://github.com/tzutalin/labelImg> (accessed Jun. 25, 2021).
- [66] A. Kathuria and Dkobran, “GitHub - Paperspace/DataAugmentationForObjectDetection: Data Augmentation For

- Object Detection,” 2018.
<https://github.com/Paperspace/DataAugmentationForObjectDetection>
 (accessed Jun. 18, 2021).
- [67] X. W. Chen, X. Lin, A. Blumer, A. Ehrenfeucht, D. Haussler, and M. K. Warmuth, “Learnability and the Vapnik-Chervonenkis Dimension,” *J. ACM*, vol. 36, no. 4, pp. 929–965, 1989, doi: 10.1145/76359.76371.
- [68] B. Juba and H. S. Le, “Precision-Recall versus accuracy and the role of large data sets,” *33rd AAAI Conf. Artif. Intell. AAAI 2019, 31st Innov. Appl. Artif. Intell. Conf. IAAI 2019 9th AAAI Symp. Educ. Adv. Artif. Intell. EAAI 2019*, pp. 4039–4048, 2019, doi: 10.1609/aaai.v33i01.33014039.
- [69] A. Joulin, L. van Der Maaten, A. Jabri, and N. Vasilache, “Learning visual features from large weakly supervised data,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 9911 LNCS, pp. 67–84, 2016, doi: 10.1007/978-3-319-46478-7_5.
- [70] A. D. A. Ttacks, “HOW TRAINING DATA AFFECT THE ACCURACY AND ROBUSTNESS OF NEURAL NETWORKS FOR IMAGE CLASSIFICATION,” no. 2014, pp. 1–12, 2020.
- [71] J. Cho, K. Lee, E. Shin, G. Choy, and S. Do, “How much data is needed to train a medical image deep learning system to achieve necessary high accuracy?,” 2015, [Online]. Available: <http://arxiv.org/abs/1511.06348>.
- [72] K. Simonyan and A. Zisserman, “Very deep convolutional networks for large-scale image recognition,” *3rd Int. Conf. Learn. Represent. ICLR 2015 - Conf. Track Proc.*, pp. 1–14, 2015.
- [73] K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2016-Decem, pp. 770–778, 2016, doi: 10.1109/CVPR.2016.90.
- [74] K. Yoshioka, “GitHub - kentaro47/frcnn-from-scratch-with-keras: Faster

- R-CNN from scratch written with Keras,” 2019.
<https://github.com/kentaroy47/frcnn-from-scratch-with-keras> (accessed Jun. 19, 2021).
- [75] N. Bodla, B. Singh, R. Chellappa, and L. S. Davis, “Soft-NMS - Improving Object Detection with One Line of Code,” *Proc. IEEE Int. Conf. Comput. Vis.*, vol. 2017-Octob, pp. 5562–5570, 2017, doi: 10.1109/ICCV.2017.593.
- [76] S. Liu, D. Huang, and Y. Wang, “Adaptive NMS: Refining pedestrian detection in a crowd,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2019-June, pp. 6452–6461, 2019, doi: 10.1109/CVPR.2019.00662.
- [77] J. Patterson and A. Gibson, *Deep learning: A Practionar Approach*, vol. 521, no. 7553. 2017.