

# **Sistem Deteksi Bagian Tubuh Janin pada Gambar USG 2D untuk Pengukuran Biometrik dengan Kombinasi Metode *Aggregated Channel Features (ACF) Detector* dan *Faster R-CNN***

**Muhammad Rajib Arif Wijaya<sup>1</sup>, Fajar Astuti Hermawati<sup>2</sup>**

<sup>1</sup> Teknik Informatika, Universitas 17 Agustus 1945, Surabaya, Indonesia

<sup>2</sup> Teknik Informatika, Universitas 17 Agustus 1945, Surabaya, Indonesia

Email: rajib.arif998@gmail.com, fajarastuti@untag-sby.ac.id

## **Abstract**

*Biometric measurement is a critical step to determine the fetus's condition in the form of estimated fetal age, fetal nutritional status, and estimation of fetal weight. Therefore errors in estimating fetal health can increase the risk of death and abnormalities in the fetus. Biometric measurements are obtained by detecting fetal body parts using ultrasound equipment, namely the head, abdomen, and femur, where this process requires knowledge, accuracy, and experience from a reliable sonographer. The accuracy of the recognition of the fetal body area will affect the accuracy of the results of fetal biometric measurements, such as measurement of head diameter (biparietal diameter), measurement of the abdominal circumference, and measurement of femur length. These biometric measures are used to predict the weight of the fetus in the womb or predict the age of the fetus. Based on these problems, this study aims to create a detection system for fetal body parts, namely the head, abdomen, and femur, automatically on 2D ultrasound images using a combination of the *ACF Detector* object detection method and *Faster R-CNN*. This system consists of four main stages: the noise reduction stage, the application of the *ACF detector*, the application of the *CNN* method, and the *Faster R-CNN* method. The noise reduction stage aims to eliminate speckle noise by applying the *Speckle Reducing Anisotropic Diffusion* method. The *ACF Detector* method is used for the first time to obtain objects in the image that are not the head, abdomen, and femur, which are hereinafter referred to as negative images. The detection result in a negative image is then used as training data at the *CNN* method stage using a pre-trained *AlexNet* network. The training data at this stage consists of positive images and negative images. Furthermore, the learning outcomes of the *CNN* method are used at the stage of the *Faster RCNN* method to detect objects in the image that are grouped according to fetal body parts such as the head, abdomen, and femur. This method successfully detects three types of fetal body parts.*

**Keywords:** *Ultrasound image, medical image, ACF detector, Faster R-CNN, object detection.*

## **Abstrak**

*Pengukuran biometrik merupakan tahapan yang sangat penting untuk mengetahui kondisi janin yang berupa perkiraan umur janin, status gizi janin, serta estimasi berat janin, oleh karena itu kesalahan dalam perkiraan kesehatan janin dapat menyebabkan meningkatnya risiko kematian dan kelainan pada janin. Pengukuran biometrik didapatkan*

dengan mendeteksi bagian tubuh janin menggunakan alat ultrasonografi yaitu bagian kepala, bagian perut, dan bagian femur, dimana proses ini memerlukan pengetahuan, ketelitian serta pengalaman dari seorang sonografer yang handal. Ketepatan pengenalan area tubuh janin ini akan mempengaruhi akurasi dari hasil pengukuran biometrik janin, seperti pengukuran diameter kepala (*biparietal diameter*), pengukuran lingkaran perut (*abdominal circumference*) serta pengukuran panjang alat gerak janin (*femur length*). Ukuran-ukuran biometrik ini digunakan untuk memprediksi berat janin dalam kandungan atau memprediksi usia janin. Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk membuat sistem deteksi bagian tubuh janin yaitu bagian kepala, perut dan femur secara otomatis pada gambar USG 2D menggunakan gabungan metode deteksi obyek ACF Detector dan Faster R-CNN. Sistem ini terdiri dari empat tahapan utama yaitu tahap reduksi noise, penerapan ACF detector, penerapan metode CNN dan penerapan metode Faster R-CNN. Tahap reduksi noise bertujuan untuk menghilangkan *speckle noise*, dengan menerapkan metode *Speckle Reducing Anisotropic Diffusion*. Metode ACF Detector digunakan pertama kali untuk mendapatkan obyek-obyek pada gambar yang bukan bagian kepala, bagian perut, dan bagian femur, yang selanjutnya disebut dengan citra negatif. Hasil deteksi yang berupa citra negatif ini selanjutnya digunakan sebagai data training pada tahapan metode CNN menggunakan jaringan pre-trained AlexNet. Data training pada tahapan ini terdiri dari citra positif dan citra negatif. Selanjutnya hasil pembelajaran metode CNN digunakan pada tahap metode Faster RCNN untuk mendeteksi objek pada citra yang dikelompokkan menurut bagian tubuh janin seperti bagian kepala, perut, dan femur. Metode ini berhasil mendeteksi tiga jenis bagian tubuh janin.

**Kata kunci:** citra ultrasound, citra medik, ACF detector, Faster R-CNN, deteksi obyek.

## 1. PENDAHULUAN

Pengukuran biometrik merupakan tahapan yang sangat penting untuk mengetahui kondisi janin yang berupa perkiraan umur janin, status gizi janin, serta estimasi berat janin. Karena, kesalahan dalam perkiraan kesehatan janin dapat menyebabkan meningkatnya risiko kematian dan kelainan pada janin. Pengukuran biometrik yang dimaksud adalah pengukuran kepala janin (*Head Circumference*), pengukuran perut (*Abdominal Circumference*), dan pengukuran tulang paha (*Femur-length*) yang didapat pada gambar hasil pemeriksaan ultrasonografi (USG) [1].

Ultrasonografi (USG) adalah salah satu metode pencitraan yang digunakan untuk memeriksa kondisi instrumen penting dalam tubuh manusia, dengan USG dapat berinteraksi dengan bentuk, ukuran anatomi, gerakan dan jaringan di sekitarnya. Pada

umumnya pemeriksaan dengan USG bersifat non-invasif, tidak menimbulkan rasa sakit pada pasien, dapat dilakukan dengan cepat dan cukup aman bila dilakukan sesuai dengan kriteria yang ada [2]. Kualitas gambar USG tidak memenuhi standar pengolahan citra digital untuk pengukuran biometrik, maka teknik perbaikan mutu citra diperlukan untuk meningkatkan kualitas serta menghilangkan noise pada gambar [3], [4].

Tingkat deteksi kelainan dini janin relatif rendah dan sangat bervariasi tergantung pada lokasi geografis. Hal ini sebagian besar disebabkan oleh tingginya tingkat keterampilan yang diperlukan untuk sonografer untuk menavigasi pesawat gambar standar yang telah ditentukan dan mengukur standar biometrik.

Selain itu, gambar USG mempunyai beberapa kekurangan termasuk bayangan akustik, gerakan kabur dan kerendahan

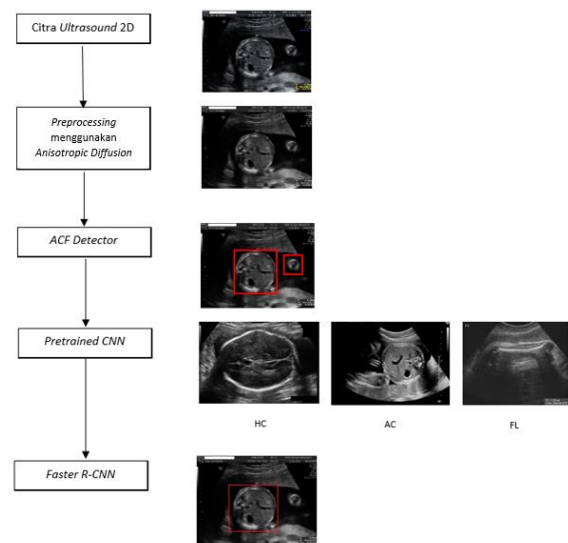
rasio *signal-to-noise*, membuat identifikasi standart planes yang menantang untuk sonografer. Selanjutnya, begitu standart planes telah diidentifikasi, ada variabilitas antar pengamat yang cukup besar dalam pengukuran struktur anatomi yang berbeda tergantung pada tingkat keahlian sonografer dan mengarahkan perhatian yang kompleks. Variasi penempatan caliper antar sonografer adalah sumber kesalahan terbesar dalam pengukuran biometrik janin hingga 80%, lebih banyak daripada kesalahan yang disebabkan oleh perbedaan orientasi janin atau anatomi pasien [5]–[7].

Pada penelitian ini dibuat sebuah sistem deteksi bagian tubuh janin ini adalah mengenali daerah pada USG janin untuk mendapatkan ukuran biometrik *head circumference*, *femur length* dan *abdominal circumference* yang didapat dari gambar hasil *ultrasound* menggunakan metode *Faster R-CNN* yang secara garis besar terdiri dari tahap perbaikan mutu, tahap *ACF Detector*, tahap *pretrained CNN* dan tahap *Faster R-CNN*. Sistem ini akan menampilkan area bagian tubuh janin yang dikenali oleh sistem dalam citra input yang dimasukkan. Proses pelatihan dilakukan menggunakan data latih berupa gambar USG bagian-bagian tubuh janin yang terdiri dari bagian kepala janin, bagian perut janin dan bagian femur janin yang diambil dari penelitian yang dilakukan oleh Hermawati et.al [8]. Sistem ini diharapkan dapat digunakan untuk mempermudah tenaga medis di dalam mengenali daerah janin yang akan diukur untuk mendapatkan prediksi berat janin atau usia janin.

## 2. METODE PENELITIAN

Skema metode yang diusulkan ditunjukkan pada Gambar 1. Pertama, *ACF detector* memproses citra latih beranotasi yang *bounding box* dari *ground truth* objek. Hasil *ACF detector* dipisahkan menjadi dua jenis, yaitu citra positif dan citra negatif. Citra

positif merupakan daerah *bounding box* yang memiliki tumpang tindih signifikan dengan daerah *ground truth*, sedangkan sisanya merupakan citra negatif. Citra negatif dari *ACF detector* dan citra *ground truth* bagian tubuh janin digunakan sebagai input dari *AlexNet CNN* yang telah dilatih sebelumnya. Selanjutnya model *CNN retrained* digunakan untuk membangun *Region Proposal Network (RPN)* pada *Faster R-CNN* kemudian melatihnya sebanyak empat tahap dengan menggunakan data training beranotasi.




Gambar 1. Skema metode yang diusulkan

### 2.1. Preprocessing

Proses pertama adalah menerapkan metode *Speckle Reducing Anisotropic Diffusion* pada citra *ultrasound 2D*, yang disebut sebagai tahap *preprocessing*. Tahap ini digunakan untuk menghilangkan *speckle noise* dengan menggunakan metode *Speckle Reducing Anisotropic Diffusion (SRAD)* adalah teknik yang bertujuan untuk mengurangi noise gambar tanpa menghilangkan bagian penting dari gambar, seperti tepi, garis, dan detail penting lainnya.

*Speckle Reducing Anisotropic Diffusion (SRAD)*, metode difusi yang disesuaikan dengan aplikasi pencitraan ultrasonik dan radar. SRAD adalah difusi sensitif tepi untuk gambar berbintik, dengan

cara yang sama seperti *conventional anisotropic diffusion* adalah difusi sensitif tepi untuk gambar yang rusak dengan noise aditif [4]. Gambar 2 menunjukkan perbedaan sebelum reduksi noise (a) dan setelah reduksi noise (b).



Gambar 2. Citra *ultrasound*: (a) sebelum reduksi *noise* dan (b) setelah reduksi *noise*.

## 2.2. Aggregated Channel Features (ACF) Detector

Tahap selanjutnya menerapkan ACF detector, dengan gambaran proses seperti pada Gambar 3. Pada tahap ini gambar *ultrasound* akan dideteksi bagian tubuh janin berupa bagian kepala, bagian perut, bagian femur dan bagian *non-object*. Dengan adanya tahap ini, bagian *non-object* diambil untuk dijadikan objek negatif pada tahap selanjutnya yaitu jaringan *pretrained CNN*. *Aggregated Channel Features (ACF)* adalah penggunaan fitur gabungan yang terdiri dari tiga saluran ruang warna LUV, saluran gradien yang dinormalisasi dan *six-channel histogram of oriented gradient (HoG)* dan kemudian disusun dalam *boosted tree* [8], [9].

## 2.3. Convolutional Neural Network (CNN)

Salah satu metode yang juga dikenal sebagai *Convolutional Neural Networks* atau *ConvNets*, adalah metode pengolahan data dalam bentuk beberapa tabel. Misalnya, gambar berwarna terdiri dari tiga larik 2D yang berisi intensitas piksel dari tiga warna berbeda. *Convolutional Neural Networks (ConvNets)* adalah aplikasi yang lebih khusus dari jaringan saraf buatan manusia (ANN) dan saat ini dianggap sebagai model

terbaik untuk memecahkan masalah pengenalan objek. Secara teknis, jaringan saraf kumulatif memiliki arsitektur yang dapat dilatih dan terdiri dari beberapa fase. Input dan output dari setiap fase adalah tabel yang disebut peta karakteristik. Misalnya, untuk gambar skala abu-abu, inputnya adalah array dua dimensi. Keluaran dari setiap langkah adalah peta fitur yang diambil dari seluruh bagian citra masukan. Setiap langkah terdiri dari tiga level: konvolusi, aktivasi, dan pengelompokan. [10].

## 2.4. Faster R-CNN

*Faster R-CNN* yang merupakan versi gabungan dari *detector Fast R-CNN* dan *R-CNN*. Jika metode *R-CNN* dan *Fast R-CNN* menggunakan metode *external region proposal*, seperti pencarian selektif, *Faster R-CNN* memperkenalkan *Region Proposal Network (RPN)* yang bersifat skala invarian dalam membagi lapisan konvolusional *CNN*. *Faster R-CNN* memiliki 2 langkah utama yaitu untuk ekstraksi dan melatih *Region Proposal* menggunakan *Region Proposal Network (RPN)* dan mengklasifikasikan objek berdasarkan kelasnya. Pada tahap latihan terdapat empat langkah, melatih *Region Proposal Network (RPN)*, melatih *fast r-cnn* menggunakan tahap 1, melatih kembali *RPN* menggunakan *weight sharing* dengan *fast r-cnn*, dan melatih kembali *fast r-cnn* menggunakan *RPN* yang telah diperbarui [11].

## 2.5. Pengukuran Performa

Pengukuran performa pada penelitian adalah untuk mengukur *average performance (AP)*. Untuk menghitung AP yang berisi kumpulan nilai dari *precision/recall*. *Precision* merupakan rasio dari jumlah *area detected cross-sectional* dan jumlah dari total *area cross-sectional*. Sedangkan *recall* merupakan jumlah dari *detected area* dan total dari jumlah kasus. Selanjutnya untuk menghitungnya akan dirumuskan pada persamaan berikut [8] :

$$AP = \frac{1}{11} \sum_{r=0}^1 \max_{\hat{r}: \hat{r} \geq r} p(\hat{r}) \quad (1)$$

Dimana  $r$  disini merupakan *recall level* dengan rentang jarak antara 0, 0.1, 0.2, 0.3, ..., 1. Sedangkan  $p(r)$  merupakan *precision level* pada nilai  $r$  tertentu.

### 3. HASIL DAN PEMBAHASAN

Sistem ini akan diuji dengan skenario berikut, yaitu menguji deteksi objek menggunakan *ACF Detector* dan *Faster RCNN* untuk mengetahui bagian tubuh janin. Sebelum mendeteksi objek, citra akan melalui proses menghilangkan *speckle noise* menggunakan *SRAD (Speckle Reducing Anisotropic Diffusion)*. Kami melakukan dua evaluasi, yaitu performa waktu proses pelatihan pada detektor *Faster R-CNN*, dan performa deteksi bagian tubuh janin. Pengujian dilakukan menggunakan komputer dengan detail isi sebagai berikut: prosesor *Intel Core i5* dengan memori 4GB dan *Single CPU*.

#### 3.1. Evaluasi Proses Pelatihan

Proses pelatihan pertama adalah melatih jaringan *pre-trained CNN* menggunakan *Alexnet*, data citra positif diambil dari dataset yang terdiri tiga kelas yaitu, bagian kepala, perut, dan femur, sedangkan citra negatif diambil dari hasil deteksi *ACF Detector* dengan nilai *confidence level* yang rendah. Proses pelatihan kedua adalah melatih *Region Proposed Network (RPN)*.

Proses pelatihan pada *Faster R-CNN detector* terdiri dari jaringan *pre-trained CNN* yang telah dilatih sebelumnya dan pelatihan *RPN*. Proses pelatihan *CNN* membutuhkan dua kategori data input, yaitu bagian tubuh janin sebagai citra positif dan *non-object* bagian tubuh janin sebagai citra negatif. Data latih yang digunakan dalam penelitian ini terbagi menjadi empat kelas. Data latih pertama terdiri dari 335 citra *head* yang

diperoleh dari penelitian van den Heuvel TLA et al [12] menggunakan mesin *USG Voluson E8* atau *Voluson 730 ultrasound device*. Sedangkan data latih kedua terdiri dari 35 citra *abdominal*, dan data latih ketiga terdiri dari 15 citra *femur* yang diambil dari penelitian Hermawati et al [4], [8], [13] yang diambil menggunakan perangkat *portable ultrasound*. Data latih *non-object* terdiri dari 72 objek yang diperoleh dari *ACF Detector*.

Tabel 1. Hasil Pelatihan Jaringan Pretrained

	Percobaan 1	Percobaan 2
Epoch	20	40
Iterasi	500	1000
Waktu	25 menit 44 detik	45 menit 01 detik
Mini-Batch	32	32
Akurasi	1	1

Berdasarkan hasil yang diperoleh pada Tabel 1, nilai epoch mempengaruhi waktu dan jumlah iterasi, semakin tinggi nilai epoch maka iterasi yang dihasilkan juga semakin banyak, waktu yang dibutuhkan juga semakin lama tetapi pada kasus waktu ini perangkat keras juga mempengaruhi, semakin bagus tingkat performa perangkat keras yang digunakan maka waktu yang dibutuhkan untuk proses latihan juga akan berkurang, pada proses pelatihan ini perangkat yang digunakan adalah *single CPU*. Epoch juga mempengaruhi hasil akurasi, semakin tinggi epoch nya maka akurasinya juga meningkat.

Pada tahap latihan *Faster RCNN* terdapat 4 langkah, melatih *Region Proposal Network (RPN)*, melatih *Faster R-CNN* menggunakan tahap 1, melatih kembali *RPN* menggunakan *weight sharing* dengan *Faster R-CNN*, dan melatih kembali *Faster R-CNN* menggunakan *RPN* yang telah diperbarui. Pada proses *training RPN*, citra *ultrasound* yang sudah dideteksi bagian tubuh janin dengan menggunakan *ACF Detector*

sebelumnya akan kita labeli untuk menghasilkan *ground truth*, setelah *ground truth* didapatkan selanjutnya akan dilakukan *training* menggunakan *anchor* dari *pretrained* CNN yang sudah kita lakukan di proses CNN, hasil yang kita peroleh dari *training* RPN adalah sebuah *feature maps*. Selanjutnya tahap pelatihan *Fast R-CNN* atau *detector* menggunakan RPN dari tahap 1 dan outputnya adalah *Box Regression*. tahap ke 3 yaitu melatih kembali RPN atau hasil dari tahap 2 dilatih lagi menggunakan CNN seperti tahap 1, terakhir melatih *detector Faster R-CNN* menggunakan RPN yang sudah di perbaharui dari tahap 3.

Setelah proses latihan jaringan *pretrained CNN*, proses latihan selanjutnya adalah tahap latihan RPN, pada tahap ini menggunakan 385 data training yang sudah dilabeli pada proses sebelumnya dan menggunakan data hasil *training* jaringan *pretrained CNN*. Hasil dari proses latihan RPN akan disajikan pada Tabel 2.

Tabel 2. Hasil Pelatihan RPN

Step 1	
Epoch	20
Iterasi	7700
Waktu	01 jam 58 menit 05 detik
Mini-Batch Accuracy	100.00%
Mini-Batch RMSE	0.64
Base Learning Rate	1.0000e-05
Step 2	
Epoch	20
Iterasi	7680
Waktu	03 jam 27 menit 23 detik
Mini-Batch Accuracy	100.00%
Mini-Batch RMSE	0.28
Base Learning Rate	1.0000e-05
Step 3	
Epoch	20
Iterasi	7700
Waktu	46 menit 59 detik

Mini-Batch Accuracy	92.97%
Mini-Batch RMSE	0.97
Base Learning Rate	1.0000e-06


#### Step 4

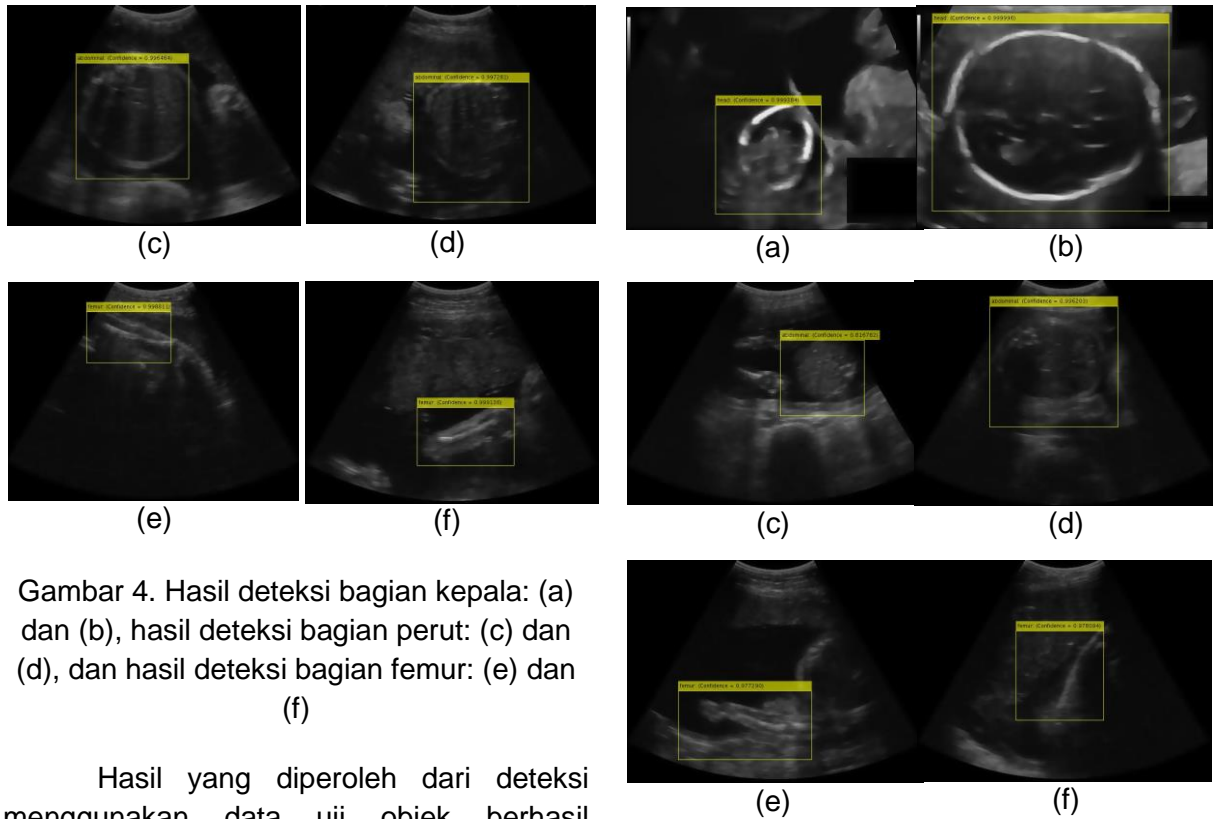
Epoch	20
Iterasi	7700
Waktu	02 jam 10 menit 55 detik
Mini-Batch Accuracy	100.00%
Mini-Batch RMSE	0.26
Base Learning Rate	1.0000e-06

Sama seperti proses latihan yang ada di CNN epoch masih menjadi salah satu faktor penentu hasil kualitas deteksi, semakin tinggi epoch yang diberikan maka juga akan berpengaruh pada hasil akurasi deteksi.

### 3.2. Evaluasi Performa Deteksi

Uji coba ini bertujuan untuk menunjukkan performa kombinasi *Faster R-CNN* dan *ACF Detector* saat mengidentifikasi objek bagian tubuh janin pada citra ultrasound. Untuk melihat performa deteksi objek bagian tubuh janin pada gambar ultrasound, kami menyajikan beberapa contoh hasil yang terdeteksi dengan skor *confidence level* tertinggi (Gambar 3) dan skor *confidence level* terendah (Gambar 4) dan beberapa yang mendeteksi objek yang tidak sesuai dengan kelasnya masing-masing (Gambar 5).






Gambar 4. Hasil deteksi bagian kepala: (a) dan (b), hasil deteksi bagian perut: (c) dan (d), dan hasil deteksi bagian femur: (e) dan (f)

Hasil yang diperoleh dari deteksi menggunakan data uji objek berhasil terdeteksi dan masuk sesuai dengan kelasnya masing masing. Untuk hasil deteksi pada objek kepala mendapatkan hasil objek yang dideteksi sesuai kelasnya yaitu *head* dengan *confidence level* 0.999999 dan 0.999999, selanjutnya hasil deteksi pada objek perut mendapatkan hasil objek yang dideteksi sesuai kelasnya yaitu *abdominal* dengan *confidence level* 0.996464 dan 0.997281, kemudian hasil deteksi pada objek paha mendapatkan hasil objek yang dideteksi sesuai kelasnya yaitu *femur* dengan *confidence level* 0.998811 dan 0.999136. Dari hasil tersebut kualitas gambar dan kejelasan objek citra mempengaruhi performa deteksi, bagian kepala mendapatkan hasil skor tertinggi dibandingkan bagian kelas lainnya karena jumlah datasetnya lebih banyak daripada kelas lainnya.

Gambar 4. Hasil deteksi bagian kepala: (a) dan (b), hasil deteksi bagian perut: (c) dan (d), dan hasil deteksi bagian femur: (e) dan (f)


Hasil yang diperoleh dari deteksi menggunakan data uji objek berhasil terdeteksi dan masuk sesuai dengan kelasnya masing masing. Untuk hasil deteksi pada objek kepala mendapatkan hasil objek yang dideteksi sesuai kelasnya yaitu *head* dengan *confidence level* 0.999284 dan 0.991648, selanjutnya hasil deteksi pada objek perut mendapatkan hasil objek yang dideteksi sesuai kelasnya yaitu *abdominal* dengan *confidence level* 0.816782 dan 0.974864, kemudian hasil deteksi pada objek paha mendapatkan hasil objek yang dideteksi sesuai kelasnya yaitu *femur* dengan *confidence level* 0.977290 dan 0.978094. Dari hasil tersebut kualitas gambarnya kurang bagus dan kejelasan objek pada citra tersebut masih kurang sehingga hasil skor *confidence level* lebih rendah dibandingkan yang lain.



Gambar 7. Hasil deteksi yang tidak sesuai

Hasil yang diperoleh dari deteksi menggunakan data uji objek berhasil terdeteksi tetapi tidak sesuai dengan kelasnya masing masing. Untuk hasil deteksi pada bagian tubuh janin berupa *femur* namun ini tidak sesuai dengan kelasnya yaitu *abdominal*, selanjutnya hasil deteksi pada objek *femur* tidak sesuai dengan kelasnya karena mendeteksi berupa *abdominal*, seharusnya hasil deteksi yang sebenarnya yaitu *femur*. Dari hasil tersebut citra yang dideteksi tidak sesuai dengan kelasnya karena citra tersebut mirip dengan objek yang lainnya sehingga sistem kurang akurat dalam mengidentifikasi objek yang sesuai dengan kelasnya.

Hasil dari pengujian tingkat keakuratan dari 50 kali percobaan adalah 90% untuk pengelompokan 3 kelas, Untuk mengukur performa rata-rata keseluruhan dapat diperoleh dengan menjumlah semua hasil uji *confidence level* sebanyak 50 data uji kemudian dibagi dengan jumlah data uji, maka dapat diperoleh sebesar 0.9629873. Untuk mengukur performa deteksi tiap kelas secara kuantitatif kita akan menggunakan perhitungan *average precision* yang berisi nilai *precision/recall* dari tiap kelas yang ada, *average precision* akan ditampilkan menggunakan sebuah grafik berisi nilai *precision/recall*.



Gambar 6. Grafik *precision/recall*

Gambar 6 menyajikan data tentang performa deteksi tiap kelas pada saat proses validasi menggunakan Faster R-CNN, untuk kelas head performa mulai menurun saat nilai recall melebihi 0.8, sedangkan kelas abdominal performanya mulai menurun pada saat nilai recall melebihi 0.4, kemudian kelas femur memiliki performa deteksi yang paling rendah dari 2 kelas yang lainnya, performanya mulai menurun saat recall berada di nilai 0.3.

Tabel 3. *Average Precision*

Bagian Tubuh Janin	<i>Average Precision</i>
<i>Head</i>	0.9718
<i>Abdominal</i>	0.9142
<i>Femur</i>	0.7055

Pada tabel 3 merupakan hasil *average precision*, pada bagian tubuh janin berupa bagian kepala (*head*) dengan jumlah data 335 mendapatkan hasil 0.9718, kemudian bagian perut (*abdominal*) dengan jumlah data 35 mendapatkan hasil 0.9142, sedangkan bagian paha (*femur*) dengan jumlah data 15 mendapatkan hasil terendah yaitu 0.7055. Dari hasil tersebut salah satu faktor besar kecilnya *average precision* adalah jumlah datanya.



#### 4. SIMPULAN

Hasil latih saat hanya menggunakan jaringan *pretrained CNN* meningkat dengan tinggi setelah digabungkan dengan RPN dan menjadi *Faster RCNN*. Metode ini berhasil mendeteksi bagian tubuh janin. Beberapa objek yang kurang jelas tidak dapat dideteksi dengan baik, hasil yang kurang baik juga didapatkan karena jumlah data latihan yang terbatas, kemudian metode *Faster RCNN* ini juga bergantung dengan jumlah epoch yang di masukkan, semakin tinggi nilai epoch maka akurasi dari deteksi juga ikut naik, intinya metode ini semakin sering dilatih maka hasilnya semakin baik. Sistem ini berhasil mendeteksi total 3 kelas dan tingkat presisi *bounding box* dari 50 data uji, sistem ini memiliki akurasi sebesar 90% dari hasil 50 data uji, kemudian skor rata-rata *confidence level* sebesar 0.9629873. Sistem Deteksi Bagian Tubuh Janin ini diharapkan akan mempermudah sonografer pada daerah di Indonesia yang kurang memiliki tenaga medis ahli dalam hal menentukan bagian tubuh janin untuk pengukuran biometrik. Kemudian untuk hasil *average precision* masing-masing bagian kepala (head) mendapatkan hasil 0.9718, kemudian bagian perut (abdominal) mendapatkan hasil 0.9142, mendapatkan hasil terendah yaitu 0.7055. Sistem Deteksi Bagian Tubuh Janin ini diharapkan akan mempermudah sonografer pada daerah di Indonesia yang kurang memiliki tenaga medis ahli dalam hal menentukan bagian tubuh janin untuk pengukuran biometrik.

#### DAFTAR PUSTAKA

- [1] L. Lindström, M. Ageheim, O. Axelsson, L. Hussain-Alkhatieb, A. Skalkidou, and E. Bergman, "Swedish intrauterine growth reference ranges of biometric measurements of fetal head, abdomen and femur," *Scientific Reports*, vol. 10, no. 1, pp. 1–17, 2020.
- [2] F. A. Hermawati, Sugiono, and Evonda, "Ultrasound Image Formation from Doppler Transducer," in *Advanced Materials Techniques, Physics, Mechanics and Applications*, S.-H. Chang, I. A. Parinov, and M. A. Jani, Eds. Springer International Publishing, 2017, pp. 535–543.
- [3] F. A. Hermawati, S. Sugiono, and R. Octaviany, "Restorasi Citra Ultrasound Medis untuk Menghilangkan Speckle Noise dengan Metode Modified Speckle Reducing Anisotropic Diffusion," in *Seminar Nasional Otomasi Industri dan Teknologi Informasi 2015 (SNOITI 2015)*, 2015.
- [4] F. A. Hermawati, H. Tjandrasa, and N. Suciati, "Hybrid Speckle Noise Reduction Method for Abdominal Circumference Segmentation of Fetal Ultrasound Images," *International Journal of Electrical and Computer Engineering (IJECE)*, vol. 8, no. 3, pp. 1747–1757, 2018.
- [5] I. Sarris *et al.*, "Intra- and interobserver variability in fetal ultrasound measurements," *Ultrasound in Obstetrics and Gynecology*, vol. 39, no. 3, pp. 266–273, 2012.
- [6] C. C. Ohagwu, H. I. Onoduagu, C. U. Eze, K. Ochie, and C. I. Ohagwu, "Intra- and inter-observer reproducibility study of gestational age estimation using three common foetal biometric parameters: Experienced versus inexperienced sonographer," *Radiography*, vol. 21, no. 1, pp. 54–60, 2015.
- [7] E. O. Ohuma *et al.*, "Fetal growth velocity standards from the Fetal Growth Longitudinal Study of the INTERGROWTH-21st Project," *American Journal of Obstetrics and Gynecology*, vol. 224, no. 2, pp. 208.e1–208.e18, 2021.
- [8] F. A. Hermawati, H. Tjandrasa, and N. Suciati, "Combination of Aggregated Channel Features (ACF) detector and Faster R-CNN to improve object

- detection performance in fetal ultrasound images,” *International Journal of Intelligent Engineering and Systems*, vol. 11, no. 6, 2018.
- [9] D. Ribeiro, J. C. Nascimento, A. Bernardino, and G. Carneiro, “Improving the Performance of Pedestrian Detectors using Convolutional Learning,” *Pattern Recognition*, vol. 61, pp. 641–649, 2017.
- [10] Y. LeCun, K. Kavukcuoglu, and C. Farabet, “Convolutional networks and applications in vision,” *ISCAS 2010 - 2010 IEEE International Symposium on Circuits and Systems: Nano-Bio Circuit Fabrics and Systems*, no. May 2014, pp. 253–256, 2010.
- [11] R. Girshick, “Fast R-CNN,” in *Proceedings of the IEEE International Conference on Computer Vision*, 2015, vol. 2015 Inter, pp. 1440–1448.
- [12] T. L. A. van den Heuvel, D. de Bruijn, C. L. de Korte, and B. van Ginneken, “Automated measurement of fetal head circumference using 2D ultrasound images,” *PloS one*, vol. 4, pp. 1–20, 2018.
- [13] F. A. Hermawati, H. Tjandrasa, Sugiono, G. I. P. Sari, and A. Azis, “Automatic femur length measurement for fetal ultrasound image using localizing region-based active contour method,” *Journal of Physics: Conference Series*, vol. 1230, no. 1, 2019.