

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

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

<sup>1 2</sup> Teknik Informatika, Universitas 17 Agustus 1945 Surabaya

Email Correspondence Author: fajarastuti@untag-sby.ac.id

**Abstract** — Biometric measurement is an essential step to determine the condition of the fetus in the womb. The accuracy of the recognition of this fetal body area will affect the accuracy of fetal biometric measurements. This study aims to create an automatic detection system for fetal body parts, namely the head, abdomen, and femur, on 2D ultrasound images using a combination of ACF detector object detection methods 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 detection results with the ACF detector with low confidence are used as negative learning data when implementing the CNN method. This method successfully detects three types of fetal body parts.

**Keyword** — Ultrasound image, medical image, ACF detector, Faster R-CNN, object detection.

**Abstrak** — Pengukuran biometrik merupakan tahapan yang sangat penting untuk mengetahui kondisi janin dalam kandungan. Ketepatan pengenalan area tubuh janin ini akan mempengaruhi akurasi dari hasil pengukuran biometrik janin. Penelitian ini bertujuan untuk membuat sistem deteksi bagian tubuh janin yaitu bagian kepala, perut dan femur secara otomatis pada gambar ultrasound 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. Hasil deteksi dengan ACF detector dengan confidence rendah digunakan sebagai data pembelajaran negatif pada tahap penerapan metode CNN. Metode ini berhasil mendeteksi tiga jenis bagian tubuh janin.

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

## I. 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) merupakan salah satu *imaging diagnostic* yang digunakan untuk pemeriksaan keadaan alat-alat vital dalam tubuh manusia, dengan USG dapat dipelajari bentuk, ukuran anatomis, gerakan serta hubungan

dengan jaringan di sekitarnya. Pada umumnya pemeriksaan dengan USG bersifat non-invasif, tidak menimbulkan rasa sakit pada penderita, dapat dilakukan dengan cepat dan cukup aman jika dilakukan dengan standarisasi 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].

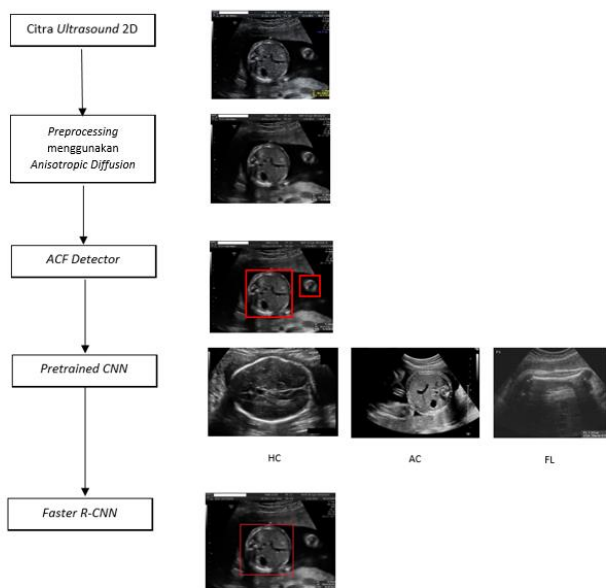
Tingkat deteksi kelainan dini janin relatif rendah dan sangat bervariasi tergantung pada lokasi geografis. Hal ini sebagian besar disebabkan oleh tingginya tingkat keterampilan yang diperlukan untuk sonografer untuk menavigasi pesawat gambar standar yang telah ditentukan dan mengukur standar biometrik.

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.

## II. 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

### A. 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*, yang merupakan teknik yang bertujuan mengurangi noise citra tanpa menghapus bagian-bagian yang signifikan dari citra, seperti tepi, garis atau rincian lainnya yang penting.

*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

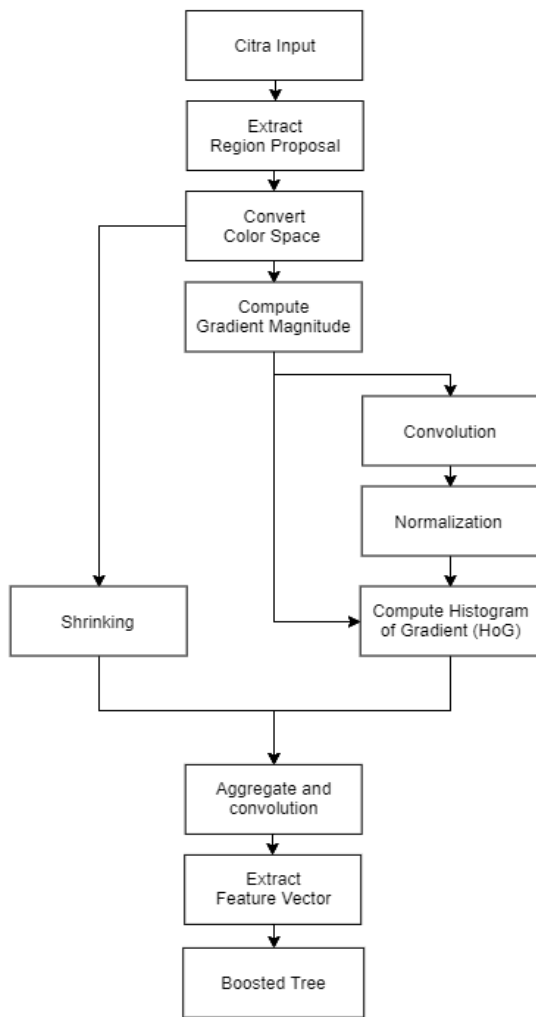
menunjukkan perbedaan sebelum reduksi noise (a) dan setelah reduksi noise (b).



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

### B. 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].



Gambar 3. Blok diagram ACF detector

### C. Convolutional Neural Network (CNN)

Convolutional Neural Network atau dikenal juga dengan sebutan ConvNets adalah sebuah metode untuk memproses data dalam bentuk beberapa array, contohnya yaitu gambar berwarna yang terdiri dari tiga array 2D yang mengandung intensitas piksel dalam tiga jenis warna. Convolutional Neural Networks (ConvNets) merupakan penerapan dari Artificial Neural Networks (ANN) yang lebih istimewa dan saat ini diklaim sebagai model terbaik untuk memecahkan masalah pengenalan objek. Secara teknis, convolutional neural network memiliki arsitektur yang dapat dilatih dan terdiri dari beberapa tahap. Masukan dan keluaran dari masing-masing tahap adalah beberapa array yang disebut feature map atau peta fitur. Contohnya untuk citra greyscale, input atau masukan adalah berupa matriks dua dimensi. Output dari masing-masing tahap adalah feature map hasil pengolahan dari semua lokasi pada citra masukan. Masing-masing tahap terdiri dari tiga lapisan yaitu konvolusi, aktivasi dan pooling [10].

### D. 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].

### E. 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.

## III. IMPLEMENTASI

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 spesifikasi sebagai berikut: prosesor Intel Core i5 dengan memori 4GB dan Single CPU.

### A. 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 I  
HASIL PELATIHAN JARINGAN PRETRAINED CNN

	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 II  
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.



#### B. 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 4) dan skor *confidence level* terendah (Gambar 5) dan beberapa yang mendeteksi objek yang tidak sesuai dengan kelasnya masing-masing (Gambar 6).




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 5. 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 6. 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.

Untuk mengevaluasi performa hasil deteksi, berikut ini adalah perhitungan akurasi dari uji coba sistem dan uji coba langsung :

$$\frac{\sum A}{\sum B} \times 100\% = \frac{91}{100} \times 100\% = 91\% \quad (2)$$

Dimana  $\sum A$  merupakan jumlah percobaan yang bernilai benar dan  $\sum B$  merupakan jumlah semua percobaan.

Hasil dari pengujian tingkat keakuratan dari 100 kali percobaan adalah 91% untuk pengelompokan 3 kelas, Untuk mengukur performa rata-rata keseluruhan dapat diperoleh dengan menjumlah semua hasil uji *confidence level* sebanyak 100 data uji kemudian dibagi dengan jumlah data uji, maka dapat diperoleh sebesar 0.9629873.

#### IV. KESIMPULAN

Hasil latihan 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 100 data uji, sistem ini memiliki akurasi sebesar 91% dari hasil 100 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 biometric.

#### DAFTAR ACUAN

- [1] L. Lindström, M. Ageheim, O. Axelsson, L. Hussain-Alkhateeb, 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.