Deteksi Otomatis Bidang Kepala Janin dari Citra Ultrasonografi 2 Dimensi

Cahya Perbawa Aji, Tri Arief Sardjono, dan Muhammad Hilman Fatoni Departemen Teknik Biomedik, Institut Teknologi Sepuluh Nopember (ITS) *e-mail*: sardjono@bme.its.ac.id

Abstrak—Modalitas pencitraan primer untuk pemeriksaan anatomi dan fisiologi janin adalah alat ultrasonografi (USG) medis 2 dimensi mengingat harganya yang murah, ketersediaan yang melimpah, kemampuan realtime, dan tidak adanya bahaya radiasi. Head Circumference (HC) merupakan parameter pengukuran biometri janin yang dianalisa untuk mengetahui perkembangan janin secara kuantitatif dengan menggunakan mesin USG. Pada praktik klinis, karena rasio signal-to-noise yang rendah, klinisi seringkali mengalami kesulitan untuk mengenali bidang janin dengan tepat. Lebih dari itu, klinisi kesulitan untuk membuat elips yang paling mendekati hanya dengan tiga titik parameter minor dan mayor yang disediakan mesin USG. Proses deteksi dan pengukuran HC secara manual oleh klinisi membutuhkan waktu yang cukup lama dan akurasinya sangat bergantung dengan pengalaman dan kemampuan klinisi. Penelitian mengenai deteksi dan pengukuran otomatis HC sedang menjadi bidang penelitian yang cukup aktif. Dalam penelitian ini diajukan sebuah sistem deteksi otomatis untuk HC. Metode Convolutional Neural Network (CNN) diajukan untuk melakukan klasifikasi bidang elips janin dari jaringan ibu maupun jaringan janin lainnya. CNN dipekerjakan untuk pixel-wise classification citra ke dalam kelas bidang janin, maternal tissue, ataupun background. Pada penelitian ini, dari 13 citra uji, didapatkan rata rata akurasi segmentasi semantik sebesar 0.76.

Kata Kunci—Convolutional Neural Network, Head Circumference, Semantic Segmentation.

I. PENDAHULUAN

PENELITIAN mengenai deteksi dan pengukuran otomatis HC dari citra USG 2 Dimensi merupakan bidang penelitian yang cukup aktif. Modalitas primer untuk memperkirakan kesehatan janin adalah alat ultrasonografi (USG) 2D (2 Dimensi) mengingat harganya yang murah, ketersediaan yang melimpah, kemampuan realtime, dan tidak adanya bahaya radiasi. Sejauh ini, setidaknya satu pemeriksaan rutin dengan alat USG pada pertengahan minggu ke 18-22 pembuahan wajib dilakukan [1]. Citra yang dihasilkan pemindaian janin menggunakan USG 2D menjadi salah satu tolok ukur utama untuk memperkirakan perkembangan janin.

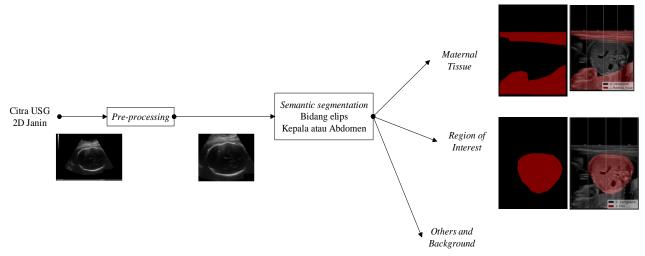
Perkembangan janin dapat dianalisa secara kualitatif contohnya kerja jantung janin dan kuantitatif contohnya pengukuran biometri janin yang mana akan dibahas dalam penelitian ini. Pengukuran biometri dilakukan untuk memperkirakan kelainan pertumbuhan janin serta estimasi berat janin dan *Gestational Age* (GA). Estimasi berat janin dan GA yang akurat penting untuk memberikan perlakuan optimal selama masa kehamilan [2]. Pengukuran biometri

janin meliputi pengukuran *Biparietal Diameter* (BPD), *Head Circumference* (HC), *Abdominal Circumference* (AC) dan *Femur Length* (FL) [3]. HC merupakan pengukuran lingkar kepala janin yang sangat prediktif untuk memprediksi GA.

Pada praktik klinis, deteksi dan pengukuran HC dilakukan secara semi otomatis. Secara manual, klinisi perlu mengarahkan probe untuk mendapatkan tampilan bidang kepala atau abdomen janin yang tepat sesuai dengan ketentuan anatominya. Tampilan bidang yang tepat merupakan syarat untuk mendapatkan pengukuran yang dapat diterima. Dari tampilan bidang yang tepat klinisi kemudian meletakkan kaliper parameter elips dimana selanjutnya mesin USG secara otomatis membentuk elips berdasarkan kaliper yang sudah ditentukan dan menghitung lingkar elips tersebut. Namun, karena rasio signal-to-noise yang rendah, klinisi seringkali kesulitan untuk mengenali dan membedakan bidang maternal tissue dan bidang janin berikut dengan validasi penerimaan bidang janin yang tepat. Pengukuran manual HC janin tetap merupakan tugas yang menantang dan memakan waktu bahkan untuk klinisi yang berpengalaman [4].

Deteksi serta lokalisasi dari bidang standar janin menjadi modal dasar untuk pengukuran biometri. Namun, proses ini membutuhkan pengetahuan mengenai anatomi dan persepsi spasial yang tinggi sehingga akurasinya sangat bergantung pada pengalaman dan pengetahuan operator. Bahkan, identifikasi sebuah struktur dari citra yang sudah jelas bisa jadi merupakan tugas yang sangat menantang terutama untuk operator yang belum ahli. Hal ini menimbulkan variabilitas deteksi dan lokalisasi berikut dengan pengukuran biometri janin baik inter maupun intra klinisi. Variabilitas ini dapat menyebabkan diagnosis kehamilan yang tidak tepat.

Pada saat yang bersamaan, dunia mengalami kekurangan sonographer yang berpengalaman. Masalah ini sangat terlihat terutama pada negara berkembang, dimana menurut World Health Organization (WHO), banyak USG yang digunakan oleh sonographer yang sedikit atau tidak melakukan formal training [1]. Pengembangan sistem deteksi dan pengukuran HC secara otomatis menjadi sangat penting di Indonesia sebagai salah satu negara berkembang di dunia. Sistem deteksi bidang kepala secara otomatis diharapkan menyelesaikan permasalahan variabilitas pengukuran dengan menjadi informasi pendukung pengambilan keputusan oleh klinisi. Dengan begitu, perbedaan pengukuran antara klinisi dengan pengalaman yang sedikit dan banyak dapat dikurangi. Alhasil, diagnosis kehamilan (terutama diagnosis umur ukuran, serta berat janin) menjadi akurat. Lebih dari itu, diagnosis yang akurat dapat digunakan sebagai dasar dalam



Gambar 1. Diagram blok sistem secara umum.

menentukan perkembangan janin yang tidak normal lebih akurat.Salah satu penelitian yang cukup dikenal untuk mendeteksi dan mengukur HC secara otomatis adalah [4], dimana pada penelitian ini, digunakan Random Forest Classifier untuk ekstraksi ROI HC. Penggunaan Random Forest Classifier memiliki performa yang cukup baik. Namun, klasifikasi ini membutuhkan prior knowledge yang baik untuk merancang sistem. Setelahnya, penelitian yang dilakukan Kim et al [5] dilakukan dengan menggunakan CNN. Dalam penelitian tersebut, cara paling akurat untuk batas kepala oleh U-Net mendeteksi mengklasifikasikan setiap piksel menjadi empat kelas yang berbeda: jaringan ibu memiliki pola arah horizontal, batas kepala atas memiliki pola busur cekung, batas kepala bawah memiliki pola busur cembung, dan yang tersisa.

Dalam penelitian ini, diusulkan sebuah sistem yang dapat melakukan proses deteksi otomatis HC menggunakan CNN. Pemilihan metode CNN digunakan karena CNN dapat menjadi *classifier* yang *robust* untuk citra USG janin [1], [6], [7]. CNN akan digunakan untuk melakukan segmentasi semantik terhadap tiga kelas yaitu bidang elips, *maternal* tissue, dan background.

II. PERANCANGAN SISTEM

A. Desain system secara umum

Secara umum, alur kerja sistem yang akan dibuat dijelaskan dalam diagram blok pada Gambar 1. Pada praktik klinis, terdapat beberapa langkah untuk mendapatkan HC atau AC yang dapat dipercaya. Pada penelitian ini, langkahlangkah tersebut diuraikan dalam tiga langkah. Pertama, klinisi mencoba untuk mengarahkan probe untuk mencari struktur batasan bidang kepala ataupun abdomen janin. Kedua, klinisi mencoba mengenali struktur struktur di dalam lingkaran tersebut dibantu dengan beberapa parameter seperti gain dan frekuensi pada USG. Ketiga, jika sudah tepat bentuk dan posisinya, klinisi akan melakukan pengukuran HC ataupun AC secara semi-otomatis dibantu oleh mesin USG dimana klinisi meletakkan beberapa parameter berupa titik bidang mayor dan minor elips selanjutnya mesin USG secara otomatis menentukan kelilingnya. Syarat utama penentuan HC dan AC yang tepat adalah peletakan probe dan pengaturan parameter pada alat USG yang tepat untuk mendapatkan citra bidang head dan abdomen yang tepat sesuai dengan ketentuan anatomi yang ada untuk mendapatkan hasil pengukuran yang dapat dipercaya.

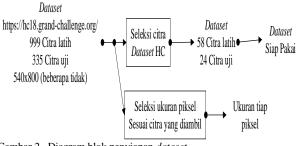
Alur kerja dari penelitian ini ditujukan untuk menjadi pendukung klinisi pada tahap pertama dan kedua. Pertama, citra USG 2D sebagai masukan melalui *image preprocessing* untuk selanjutnya menjadi masukan proses pendeteksian bidang kepala janin secara umum. Proses deteksi secara otomatis dilakukan dengan memanfaatkan metode CNN yang digunakan untuk mengklasifikasikan setiap pixel ke dalam bidang kepala ataupun abdomen dari kelas lain seperti *maternal tissue* dan bagian lain yang dianggap sebagai *background*. Klasifikasi dengan CNN digunakan karena diharapkan CNN mampu untuk melakukan klasifikasi citra USG 2 dimensi janin yang memiliki kompleksitas bentuk yang tinggi dengan intensitas piksel yang dibatasi pada satu *channel grayscale* saja.

B. Dataset

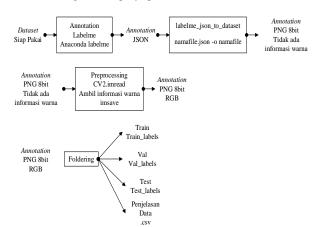
Dataset yang digunakan dalam penelitian ini digunakan untuk melatih CNN dan menguji sistem secara umum. Dataset bidang kepala yang akan diguanakan akan didapatkan dari "Grand Challenges in Biomedical Image Analysis" bidang Head Circumference yang berisi database citra USG 2 dimensi bidang kepala janin. Dataset ini terdiri dari total 1334 gambar ultrasound dua dimensi (2D) dari bidang standar yang dapat digunakan untuk mengukur HC. Data dapat diunduh dari [8]. Data ini dibagi menjadi satu set pelatihan 999 gambar dan satu set uji 335 gambar. Ukuran setiap gambar USG 2D adalah 800 x 540 piksel dengan ukuran piksel mulai dari 0,052 hingga 0,326 mm. Ukuran piksel untuk setiap gambar dapat ditemukan di file csv: 'training set pixel size and HC.csv' dan 'test set pixel_ size.csv'. Set pelatihan juga mencakup gambar dengan anotasi manual lingkar kepala untuk setiap HC, yang dibuat oleh seorang ahli sonografi yang terlatih. File csv 'training_set_pixel_size_and_HC.csv' termasuk pengukuran lingkar kepala (dalam milimeter) untuk setiap HC yang beranotasi dalam set pelatihan.

C. Penyiapan Dataset

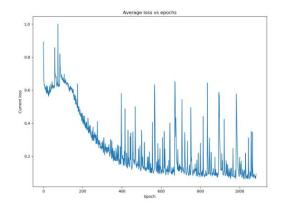
Sebelum siap untuk menjadi dataset, data tersebut harus melalui seleksi secara manual dan *pre-processing*. Proses seleksi citra *dataset* dilakukan dengan memilih citra yang



Gambar 2. Diagram blok penyiapan dataset.



Gambar 3. Diagram blok penyiapan data anotasi.



Gambar 4. Perbandingan loss dan epoch.

digunakan dalam pelatihan dan pengujian adalah citra yang menyerupai data *raw* dari US. Karena dari total 1334 citra HC yang ada dalam dua berkas pelatihan dan pengujian ada banyak citra yang sudah dilakukan proses cropping dan praproses lainnya, data tersebut dipindai secara manual untuk diseleksi hanya citra yang masih tampak seperti citra raw yang diambil dari mesin USG langsung saja. Dari berkas pelatihan, diambil 58 citra dan dari berkas pengujian diambil 24 citra sehingga total ada 82 citra yang akan digunakan untuk proses pelatihan dan pengujian. Selanjutnya sesuai dengan nama berkas citra yang akan digunakan, data ukuran piksel juga diseleksi sehingga dalam satu berkas hanya terdapat ukuran piksel bagi citra citra yang akan digunakan saja. Proses penyiapan dataset dapat dijelaskan dalam diagram blok pada Gambar 2. Secara umum penyiapan dataset untuk proses pembelajaran CNN dijelaskan dalam Gambar 3. Karena pada bagian ini, CNN digunakan untuk melakukan pixel-wise classification, maka proses anotasi harus dilakukan pada dimensi spasial untuk setiap pikselnya.

Tabel 1. Arsitektur CNN

Input	Transformed Image				
1	512 x 512 x 1				
Layer	Type	Feature Maps	Filter	Stride	
1		512 · · 512 · · 64	Size		
1	conv×2	512 × 512 × 64	3×3	1	
2	maxpool	$256 \times 256 \times 64$	2×2	2	
3	conv×2	$256 \times 256 \times 128$	3×3	1	
4	maxpool	$128 \times 128 \times 128$	2×2	2	
5	conv×2	$128 \times 128 \times 256$	3×3	1	
6	maxpool	$64 \times 64 \times 256$	2×2	2	
7	conv×2	$64 \times 64 \times 512$	3×3	1	
8	maxpool	$32 \times 32 \times 512$	2×2	2	
9	conv	$32 \times 32 \times 1024$	3×3	1	
10	conv	$32 \times 32 \times 512$	3×3	1	
11	transposed	$64 \times 64 \times 512$	2×2	2	
12	concat7	$64 \times 64 \times 1024$	-	-	
13	Conv	$64 \times 64 \times 512$	3×3	1	
14	Conv	$64 \times 64 \times 256$	3×3	1	
15	Transposed	$128\times128\times256$	2×2	2	
16	concat5	$128\times128\times512$	-	-	
17	Conv	$128\times128\times256$	3×3	1	
18	Conv	$128\times128\times128$	3×3	1	
19	Transposed	$256\times256\times128$	2×2	2	
20	concat3	$256\times256\times256$	-	-	
21	Conv	$256\times256\times256$	3×3	1	
22	Conv	$256 \times 256 \times 64$	3×3	1	
23	Transposed	$512 \times 512 \times 64$	2×2	2	
24	concat1	$512\times512\times128$	-	-	
25	conv×2	$512\times512\times64$	3×3	1	
Out	Conv	512 × 512 × 3	3×3	1	

Tabel 2.

Nomor	Nama File	Akurasi
1	53.png	0.80
2	54.png	0.73
3	55.png	0.80
4	56.png	0.80
5	57.png	0.56
6	58.png	0.65
7	59.png	0.82
8	60.png	0.76
9	61.png	0.75
10	62.png	0.82
11	63.png	0.78
12	64.png	0.76
13	65.png	0.89
R	0.76	

Untuk mempermudah proses ini, program bernama Labelme digunakan karena program ini merupakan salah satu program yang open source. Proses ini dilakukan dengan memberi batasan berupa titik titik polygon untuk region yang akan diberi anotasi. Setelah proses dilakukan untuk keseluruhan dataset, maka akan terbentuk satu berkas dalam format .json untuk setiap citra, berapapun jumlah kelas di dalam citra tersebut. Selanjutnya, format tersebut harus diubah menjadi berkas .png untuk selanjutnya nilai tiap pikselnya dibaca oleh CNN sebagai desired output. Untuk proses tersebut, labelme memberikan fitur untuk melakukan konversi format .json menjadi sebuah folder yang berisi citra anotasi dalam format .png. Untuk itu sebuah algoritma dibuat untuk secara otomatis membuka semua file hasil ubahan format tersebut dan mengambil citra anotasi. Setelah itu semua data tersebut dibagi ke dalam folder train, val, dan tes. Berkas train berisi data citra yang akan digunakan untuk proses learning.

Berkas *val* dilakukan untuk melakukan proses validasi untuk setiap jumlah *epoch* tertentu dengan menghasilkan citra hasil prediksi dan penghitungan nilai kesalahan. Sedangkan citra *test* digunakan untuk pengujian sistem CNN maupun sistem secara keseluruhan.

Proses selanjutnya adalah penyiapan anotasi. Secara umum proses ini dijelaskan pada Gambar 3. Karena pada bagian ini, CNN digunakan untuk melakukan pixel-wise classification, maka proses anotasi harus dilakukan pada dimensi spasial untuk setiap pikselnya. Untuk mempermudah proses ini, program bernama Labelme digunakan karena program ini merupakan salah satu program yang open source. Proses ini dilakukan dengan memberi batasan berupa titik titik polygon untuk region yang akan diberi anotasi. Setelah proses dilakukan untuk keseluruhan dataset, maka akan terbentuk satu berkas dalam *format* .json untuk setiap citra, berapapun jumlah kelas di dalam citra tersebut. Selanjutnya, format tersebut harus diubah menjadi berkas .png untuk selanjutnya nilai tiap pikselnya dibaca oleh CNN sebagai desired output. Untuk proses tersebut, labelme memberikan fitur untuk melakukan konversi format .json menjadi sebuah folder yang berisi citra anotasi dalam format .png. Untuk itu sebuah algoritma dibuat untuk secara otomatis membuka semua file hasil ubahan format tersebut dan mengambil citra anotasi. Setelah itu semua data tersebut dibagi ke dalam folder train, val, dan test. Berkas train berisi data citra yang akan digunakan untuk proses learning. Berkas val dilakukan untuk melakukan proses validasi untuk setiap jumlah epoch tertentu dengan menghasilkan citra hasil prediksi dan penghitungan nilai kesalahan. Sedangkan citra test digunakan untuk pengujian sistem CNN maupun sistem secara keseluruhan.

D. Perancangan Arsitektur CNN

Arsitektur jaringan CNN berdasarkan U-net yang akan digunakan diilustrasikan pada Tabel 1. Arsitektur ini terdiri dari contracting path dan expansive path. Contracting path mengikuti arsitektur tipikal jaringan CNN untuk klasifikasi biasa. Arsitektur ini terdiri dari aplikasi berulang dua konvolusi 3x3 (konvolusi tidak ditambahkan), masingmasing diikuti oleh Rectified Linear Unit (ReLU) dan operasi maxpool 2x2 dengan langkah 2 piksel untuk downsampling. Setiap langkah di jalur ekspansif terdiri dari upampling peta fitur diikuti oleh konvolusi yang mana berupa transposed convolution yang membagi dua jumlah saluran fitur, gabungan dengan peta fitur yang dipangkas sesuai dari contracting path, dan dua konvolusi 3x3, masing-masing diikuti oleh ReLU. Yang membedakan arsitektur yang digunakan dibanding dengan U-net adalah adanya padding untuk setiap operasi konvolusinya. Hal ini ditujukan untuk menjaga resolusi spasial sama antara masukan dan keluaran proses konvolusi. Sedangkan, lebih dari itu, terutama untuk jumlah fitur pada setiap prosesnya, penelitian pada penelitian ini disamakan parameternya dengan alur kerja pada arsitektur U-net sesuai yang dijelaskan pada [9].

E. Perancangan Proses Learning CNN

Pada proses pembelajaran, terdapat beberapa parameter yang ditetapkan di awal. Yang pertama citra input ditentukan sebagai citra *grayscale* dengan ukuran 512 x 512 piksel. Citra dataset yang kurang lebih berukuran 540 x 800 (beberapa sedikit lebih atau kurang) kemudian melalui proses *cropping* dimana yang diambil di bagian tengah dari citra dengan

ukuran 512 x 512. Pemilihan ukuran ini didasari oleh alasan kemampuan dari memori GPU yang hanya dapat menampung citra input dengan ukuran 512 x 512. Proses *cropping* dipilih dibandingkan dengan proses *resizing* dipilih karena informasi mengenai ukuran tiap piksel penting untuk dipertahankan demi validitas pengukuran lingkar elips nantinya. Lebih dari itu proses *cropping* dengan ukuran 512 x 512 di tengah tidak menghilangkan fitur bidang janin. Sehingga input CNN *array* berukuran 512 x 512 x 1. Input ini kemudian melalui proses konversi dan array reshaping menjadi tensor array untuk menyesuaikan array library tensorflow dengan ukuran 1 x 512 x 512 x 1. Keluaran dari CNN berupa array dengan ukuran 1 x 512 x 512 x 512 x 3. Nilai 3 menandakan jumlah kelas yang ada pada CNN yang dirancang.

Untuk proses inisialisasi, semua nilai beban dan bias diatur sebagai nilai random dengan standard deviasi 1 dan rata-rata 0. Adam berbeda dengan stochastic gradient descent klasik. Stochastic gradient descent mempertahankan tingkat pembelajaran tunggal (disebut alpha) untuk semua pembaruan bobot dan tingkat pembelajaran tidak berubah selama pelatihan. Metode optimasi Adam menggabungkan keuntungan dari dua ekstensi lain dari penurunan gradien stokastik yaitu Algoritma Gradient Adaptif (AdaGrad) dan Root Mean Square Propagation (RMSProp).

Ada Grad mengalami masalah tingkat pembelajaran menghilang, tetapi AdaGrad sangat berguna untuk kasus di mana gradien kecil. Di sisi lain, RMSprop tidak mengurangi tingkat pembelajaran ke nilai yang sangat kecil pada langkah waktu yang lebih tinggi. Namun di sisi negatif, itu tidak memberikan solusi optimal untuk kasus gradien jarang. Pendekatan *ADAptive Moment* (ADAM) memperkirakan tingkat pembelajaran terpisah untuk setiap parameter dan menggabungkan positif dari AdaGrad dan RMSprop. Perbedaan utama antara Adam dan dua pendahulunya (RMSprop dan AdaDelta) adalah bahwa pembaruan diperkirakan dengan menggunakan momen pertama dan momen kedua dari gradien. Adam adalah algoritma yang populer di bidang pembelajaran mendalam karena ia mencapai hasil yang baik dengan cepat.

Sedangkan untuk nilai konvergensi, pada bagian ini digunakan batas konvergensi berupa nilai epoch maksimal yang diatur pada 10.000 epoch. Namun program diatur untuk dapat melakukan proses pause atau penghentian sementara pada epoch tertentu dan dilanjutkan kembali. Karena proses pembelajaran membutuhkan waktu yang cukup lama berhubung ukuran masukan dan keluaran yang digunakan berukuran cukup besar yaitu 512 x 512. Dalam proses pembelajaran, looping dilakukan dengan membagi ke dalam epoch, iterasi, dan batch. Jumlah batch merupakan hyperparameter yang ditetapkan di awal pembelajaran. Jumlah iterasi merupakan jumlah data dalam training dataset dibagi dengan jumlah batch. Sedangkan 1 epoch mencakup semua data dalam train dataset sehingga mencakup semua iterasi. Tujuan dibentuk looping untuk batch adalah untuk melakukan batch normalization. Batch normalization penting untuk melakukan regularization yang tujuannya untuk menghindari terjadinya overfitting. Overfitting adalah suatu kondisi yang mungkin terjadi pada proses generalisasi. Generalisasi adalah suatu proses induksi yang berusaha mengenali suatu pola dari suatu kejadian pada masa lampau untuk memprediksi kejadian pada masa yang akan datang.

Namun, pada penelitian ini, prosedur ini belum dilakukan walau *platform* sudah disediakan.

F. Metode Pengujian

Pengujian dilakukan dengan memberikan beberapa input citra kepada sistem untuk mendapatkan hasil berupa segmentasi semantik. Citra yang digunakan sebagai input adalah citra validasi pada berkas val yang sudah dijelaskan sebelumnya. Perhitungan akurasi proses segmentasi semantik dengan CNN dilakukan dengan mencari nilai *Dice Similarity Coefficient* (DSC) seperti yang digunakan pada [10] yang dijelaskan pada Persamaan 1,

$$DSC = \frac{2.|Area_{s} \cap Area_{R}}{2.|Area_{s} + Area_{R}}$$
 (1)

di mana $Area_S$ adalah area anotasi dari klinisi yang didapatkan dari dataset dan $Area_S$ adalah area segmentasi semantik oleh CNN pada sistem yang diajukan.

III. PENGUJIAN DAN HASIL

A. Pengujian

Proses learning dilakukan dengan menggunakan library Tensorflow dengan kompatibilitas penggunaan Graphical Processing Unit (GPU). Sebab, pemrograman menggunakan program fungsi dari scratch, waktu yang dibutuhkan untuk satu kali perhitungan maju adalah sekitar 10 menit. Pengujian dilakukan dengan memberikan beberapa input citra kepada sistem untuk mendapatkan hasil berupa segmentasi semantik, deteksi elips, dan nilai pengukuran lingkar elipsnya. Citra input diambil dari berkas val. Berkas tersebut berisi 13 citra USG 2 Dimensi. Pengujian dimulai dengan memilih salah satu citra yang akan diuji dari 13 citra tersebut. Selanjutnya, citra yang dipilih akan dibaca sebagai sebuah array dan ditampilkan pada user interface. Pembacaan citra sebagai sebuah array dilakukan dengan bantuan library opency. Secara default, citra akan dibaca sebagai array 3 dimensi yang dengan ukuran lebar, panjang, dan dimensi. Dimensi berjumlah tiga karena citra dibaca sebagai citra red, green, blue (RGB). Namun, karena citra ini sebenarnya merupakan citra grayscale, sehingga nilai dari ketiga channel tersebut sama. Sehingga, dapat diambil salah satu channel saja untuk menjadi array dua dimensi saja. Citra tersebut kemudian menjadi input bagi proses prediksi. Pada tahap yang bersamaan, OS digunakan untuk mendapatkan informasi mengenai nama berkas citra yang dipilih. Informasi ini penting karena secara otomatis program selanjutnya akan membaca informasi dari file .csv yang berisi informasi tentang ukuran piksel setiap citra dan hasil pengukuran HC yang dilakukan oleh klinisi sesuai yang didapatkan dari dataset. Setelah mendapatkan umpan masukan dari proses sebelumnya, proses segmentasi semantik dilakukan. Pada tahap ini, pertama dilakukan recall dari arsitektur CNN, pembacaan weight dan threshold, serta proses cropping dengan ukuran sesuai arsitektur CNN yaitu 512 x 512 dan penetapan hasil tersebut sebagai masukan CNN. Pada tahap akhir. perhitungan feedforward dilakukan mendapatkan hasil segmentasi semantik berupa citra yang lebih sederhana berupa colormap klasifikasi pixel-wise.

B. Hasil

Dengan arsitektur sesuai U-Net yang telah dimodifikasi sesuai yang dijelaskan pada Table 1, untuk 1800 epoch dan learning rate 0.1 learning dilakukan. Gambar 4 menjelaskan bagaimana performa arsitektur dengan hyperparameter dalam melakukan proses training terhadap dataset yang ada dimana menjelaskan perbandingan nilai kesalahan terhadap jumlah epoch selama proses training. Tabel 2 menunjukkan hasil akurasi pengujian untuk 13 data val.

IV. DISKUSI

Pada penelitian ini, diusulkan sebuah sistem yang dapat melakukan proses deteksi otomatis bidang kepala janin menggunakan CNN. Pemilihan metode CNN digunakan karena CNN dapat menjadi *classifier* yang *robust* untuk citra USG janin [1], [6], [7]. CNN digunakan untuk melakukan segmentasi semantik terhadap tiga kelas yaitu bidang elips, *maternal* tissue, dan background. Berbeda dengan penelitian sebelumnya, pembagian kelas yang sedemikian rupa pada penelitian ini diusulkan. Dari hasil eksperimen tersebut, didapatkan hasil akurasi yang cukup tinggi walau hanya dengan 1800 iterasi.

Penelitian ini memiliki beberapa ruang pengembangan di penelitian selanjutnya. Pertama, pada penelitian ini ukuran masukan ditentukan menjadi 512x512 piksel. Hal ini didapatkan dengan melakukan cropping citra raw. Dengan ukuran seperti ini, proses pembelajaran CNN menjadi lebih lama. Untuk meningkatkan performa dan hasil CNN, dapat dilakukan reshaping masukan menjadi ukuran yang lebih kecil. Selanjutnya, arsitektur dan penentuan jumlah fitur pada CNN pada penelitian ini dirancang berdasarkan U-Net. Namun, perlu diujicobakan arsitektur dan beberapa jumlah fitur lain. Jumlah fitur yang sangat banyak memang meningkatkan ketelitian pada segmentasi semantik. Namun, biaya komputasi akan meningkat jika jumlah fitur tersebut ditambah. Perlu dilakukan penelitian mengenai jumlah fitur dan layer yang cukup untuk klasifikasi citra USG janin 2 dimensi. Jumlah fitur minimal untuk mendapatkan hasil yang sama baik pada penerapan klasifikasi citra USG janin 2 dimensi akan menghemat proses komputasi baik learning maupun testing. Dengan melakukan ini harapannya proses komputasi lebih cepat sehingga pembelajaran dengan waktu yang sama dapat dilakukan untuk jumlah iterasi yang lebih banyak. Sehingga, dengan waktu pembelajaran yang sama, iterasi yang didapatkan lebih banyak. Kedua, dalam penelitian ini telah dilakukan pengujian sistem secara keseluruhan untuk data bidang kepala. Pengujian bidang abdomen dengan data anotasi yang baik dengan jumlah yang cukup dapat dilakukan pada penelitian selanjutnya untuk menguji robustness dari perancangan klasifikasi dengan tiga kelas untuk data bidang abdomen. Lebih dari itu, diperlukan juga informasi mengenai ukuran tiap piksel beserta hasil pengukuran manual oleh klinisi sebagai bahan validasi nilai pengukuran keliling elips hasi deteksi dalam satuan millimeter. Ketiga, untuk menguji kesesuaian hasil pengukuran HC diperlukan metode plane acceptance check. Sesuai alur pengukuran HC oleh klinisi, bidang pencitraan yang tepat merupakan syarat untuk menentukan kesesuaian nilai penerimaan pengukuran yang didapatkan. Hal ini dilaku kan dengan melakukan pengenalan bentuk dan lokasi struktur struktur dalam satu bidang hasil pencitraan 2D oleh USG. CNN yang lain dapat diperkerjakan untuk melakukan pengenalan terhadap bidang tersebut dari hasil *cropping* sesuai parameter elips yang didapatkan. Namun, hal utama yang harus dilakukan untuk melakukan proses ini adalah menyiapkan dataset yang berisi citra dan anotasi manual oleh klinisi terhadap struktur struktur janin yang ada dalam bidang kepala dan abdomen yang tepat.

V. KESIMPULAN

Sistem klasifikasi CNN untuk deteksi bidang kepala janin telah diusulkan. dengan klasifikasi tiga kelas yaitu *maternal tissue*, ROI, dan *backgruound* dari 13 citra uji, didapatkan rata rata akurasi segmentasi semantik sebesar 0.76. Hasil ini didapatkan dari 1800 iterasi pembelajaran. Penelitian ini telah dilakukan pengujian sistem secara keseluruhan untuk data bidang kepala. Pengujian bidang abdomen dengan data anotasi yang baik dengan jumlah yang cukup dapat dilakukan pada penelitian selanjutnya untuk menguji *robustness* dari perancangan klasifikasi dengan tiga kelas untuk data bidang abdomen.

DAFTAR PUSTAKA

- C. F. Baumgartner et al., "SonoNet: Real-Time Detection and Localisation of Fetal Standard Scan Planes in Freehand Ultrasound," vol. 36, no. 11, pp. 2204–2215, 2017.
- [2] N. H. Khan, E. Tegnander, J. M. Dreier, S. Eik-Nes, H. Torp, and G. Kiss, "Automatic detection and measurement of fetal femur length using a portable ultrasound device," in 2015 IEEE International Ultrasonics Symposium, IUS 2015, 2015, pp. 1–4, doi: 10.1109/ULTSYM.2015.0486.

- [3] P. W. Callen, Ultrasonography in obstetrics and gynecology. Elsevier Health Sciences. 2011.
- [4] J. Li et al., "Automatic Fetal Head Circumference Measurement in Ultrasound Using Random Forest and Fast Ellipse Fitting," *IEEE J. Biomed. Heal. Informatics*, vol. 22, no. 1, pp. 215–223, 2018, doi: 10.1109/JBHI.2017.2703890.
- [5] H. P. Kim, S. M. Lee, J. Kwon, Y. Park, K. C. Kim, and J. K. Seo, "Automatic evaluation of fetal head biometry from ultrasound images using machine learning," *Physiol. Meas.*, pp. 1–9, 2019, doi: 10.1088/1361-6579/ab21ac.
- [6] H. Chen et al., "Standard Plane Localization in Fetal Ultrasound via Domain Transferred Deep Neural Networks," *IEEE J. Biomed. Heal. Informatics*, vol. 19, no. 5, pp. 1627–1636, Sep. 2015, doi: 10.1109/JBHI.2015.2425041.
- [7] J. Jang, Y. Park, B. Kim, S. M. Lee, J. Y. Kwon, and J. K. Seo, "Automatic Estimation of Fetal Abdominal Circumference from Ultrasound Images," *IEEE J. Biomed. Heal. Informatics*, vol. 22, no. 5, pp. 1512–1520, 2017, doi: 10.1109/JBHI.2017.2776116.
- [8] Thomas L. A. van den Heuvel; Dagmar de Bruijn; Chris L. de Korte; Bram van Ginneken, "Automated measurement of fetal head circumference using 2D ultrasound images."
- [9] O. Ronneberger, P. Fischer, and T. Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation," in *Medical Image Computing and Computer-Assisted Intervention*, 2015, pp. 234–241.
- [10] T. L. A. van den Heuvel, D. de Bruijn, C. L. de Korte, and B. van Ginneken, "Automated measurement of fetal head circumference," vol. 4, pp. 1–20, 2018, doi: 10.5281/ZENODO.1322001.