

Segmentasi Citra Echocardiography Menggunakan Dense-AIDAN

Made Prastha Nugraha^{1*}, Muhammad Febrian Rachmadan Amri², Wismu Sunarmodo³

^{1,2}Sistem dan Teknologi Informasi, Institut Desain dan Bisnis Bali, Indonesia

³Badan Riset dan Inovasi Nasional

E-mail: ¹nmadeprastha@gmail.com, ²febrian.rachmadhan@gmail.com, ³wism002@brin.go.id

(* : corresponding author)

Abstrak

Penyakit jantung bawaan merupakan kelainan struktural pada jantung yang diderita sejak lahir dan sekitar 1% dari seluruh anak yang lahir mengidap penyakit ini, sehingga deteksi terhadap keadaan jantung yang tidak normal harus dilakukan sejak dini. Deteksi dapat dilakukan dengan melakukan perhitungan *tracing* area segmentasi *end systole* dan *end diastole* pada video *echocardiography* jantung. Penelitian ini bertujuan untuk melakukan segmentasi pada citra *echocardiography* menggunakan metode Dense-AIDAN. Alur penelitian yang dilakukan meliputi pengumpulan dan persiapan data, pembuatan model, serta evaluasi. Dataset yang digunakan pada penelitian ini adalah video *echocardiography* publik dari EchoNet-Dynamic yang menampilkan 4 ruang jantung. Video *echocardiography* dari dataset dikonversi terlebih dahulu menjadi citra gambar. Pembuatan citra gambar didasari dari dua *tracing* yang telah disebutkan. Citra gambar ini kemudian dibagi menjadi citra latih, validasi, dan uji. Citra latih digunakan sebagai input untuk pembuatan model latih pada Dense-AIDAN. Model data latih yang dihasilkan kemudian digunakan untuk melakukan segmentasi bilik kiri pada jantung dari citra uji yang diinput. Hasil implementasi metode Dense-AIDAN memberikan nilai *dice similarity coefficient* (DSC) sebesar 0.81 dan *intersection of union* (IoU) sebesar 0.68. Penelitian yang dilakukan menyimpulkan bahwa model Dense-AIDAN yang menggunakan *backbone* DenseNet201 memberikan hasil segmentasi yang lebih baik dibandingkan dengan ResNet50 pada citra medis, terutama citra *echocardiography*.

Kata kunci: *Echocardiography*, Jantung, *Pretrained Deep Learning*, Segmentasi

Abstract

Congenital heart disease is a structural abnormality of the heart present from birth, affecting about 1% of all newborns, which make early detection of abnormal heart conditions is essential. Detection can be performed by calculating the traced area of end-systole and end-diastole segmentation in cardiac echocardiography videos. This study aims to perform segmentation on echocardiography images using the Dense-AIDAN method. The research workflow conducted in this study includes data collection and preparation, model development, and evaluation. The dataset used in this study is the public EchoNet-Dynamic echocardiography video dataset showing the four-chamber view of the heart. The echocardiography videos from the dataset are first converted into image frames. The image frames are generated based on the two tracings mentioned above. These images are then divided into training, validation, and test sets. The training images are used as input to train the Dense-AIDAN model. The trained model is then used to segment the left ventricle of the heart from the input test images. The implementation of the Dense-AIDAN method yields a Dice Similarity Coefficient (DSC) of 0.81 and an Intersection over Union (IoU) of 0.68. The study concludes that using DenseNet201 provides better segmentation results compared to ResNet50 on medical images, especially echocardiography images.

Keywords: *Cardiac*, *Echocardiography*, *Pretrained deep learning*, *Segmentation*

1. PENDAHULUAN

Penyakit jantung bawaan (*Congenital Heart Disease*) merupakan kelainan struktural pada jantung yang diderita sejak lahir [1]. Terdapat 1,5-2 juta anak atau sekitar 1% yang lahir dengan penyakit jantung bawaan setiap tahunnya yang timbul akibat faktor lingkungan dan faktor genetik janin ataupun ibu hamil menurut WHO [2] dan terlambat untuk dideteksi sehingga menimbulkan berbagai komplikasi kesehatan saat dewasa. Oleh karena itu, deteksi dan diagnosis penyakit jantung bawaan secara dini dapat dilakukan dengan *echocardiography* [3]. *Echocardiography* menggunakan *ultrasound* untuk menangkap dan mengevaluasi struktur jantung pasien sehingga menjadikan *echocardiography* sebagai metode utama yang digunakan untuk mendiagnosa penyakit jantung bawaan [4]. Diagnosis dilakukan dengan melakukan segmentasi pada bagian

jantung yang terkait dengan baik dan presisi. Saat ini, *echocardiography* masih sangat bergantung pada segmentasi manual yang melibatkan ahli sonografi. Berdasarkan hal tersebut, dibutuhkan metode segmentasi anatomi jantung secara otomatis pada gambar *echocardiography* yang akurat untuk melakukan proses analisis dan diagnosis.

Permasalahan dalam melakukan segmentasi jantung secara dini adalah kualitas gambar *Ultrasonography* (USG) yang buruk [5]. Jantung anak hingga remaja yang berusia 20 tahun lebih bervariasi dalam hal morfologi dan penampilan dibandingkan dengan jantung orang dewasa [6] sehingga menimbulkan beberapa tantangan dalam melakukan segmentasi yaitu seperti rasio sinyal terhadap *noise* yang rendah, jumlah *noise speckle* yang bervariasi, dan adanya bayangan pada gambar USG [7]. Selain itu, pengaruh gaya pemindaian yang berbeda, protokol gambar, dan perangkat yang berbeda, misalnya, dua kolom pertama dan dua kolom terakhir berasal dari perangkat yang berbeda juga menambah tantangan dalam melakukan segmentasi *echocardiography* [8].

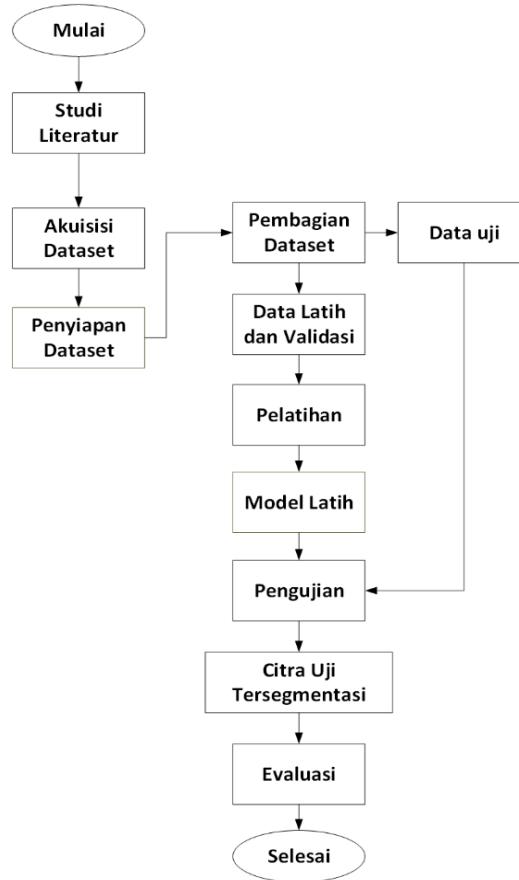
Metode *deep learning* telah diterapkan pada beberapa penelitian untuk mengatasi tantangan yang ada pada proses segmentasi, namun beberapa penelitian yang menggunakan *Convolutional Neural Network* (CNN) tidak mempertimbangkan fitur *low-level* dan *high-level* secara bersamaan [9]. Metode U-Net kemudian digunakan untuk dapat menggabungkan fitur *low-level spatial* dan fitur *high-level semantic* sekaligus memperkenalkan *skip connection* untuk meningkatkan hasil segmentasi citra, walaupun masih terdapat kekurangan, seperti kekurangnya kemampuan model untuk mempelajari fitur ataupun terdapat fitur spasial yang hilang [10]. BiSeNet kemudian digunakan untuk menutupi kekurangan dari metode U-Net [11]. BiSeNet memanfaatkan *spatial path* dan *context path* untuk menangkap fitur *low-level* dan *high-level* untuk kemudian digabungkan demi memberikan hasil prediksi yang lebih baik hingga 3% lebih baik dari metode berbasis CNN dan U-Net [12]. BiSeNet mampu memperkuat informasi global dengan fitur gabungan *low-level* dan *high-level*, namun masih memiliki kekurangan pada informasi spasial [13]. Kekurangan pada BiSeNet dapat diselesaikan dengan menambahkan *Convolutional Block Attention Module* (CBAM) untuk melakukan pembobotan fitur yang efisien dan memandu jaringan dalam mempelajari fitur yang paling diskriminatif [14], seperti yang dilakukan oleh model *Attention-Guided Dual-Path Network* (AIDAN) [8]. AIDAN dikembangkan untuk melakukan segmentasi *echocardiography* dengan mengekstrak fitur *low-level* dan *high-level* menggunakan jalur ganda, sehingga secara otomatis mengekstrak dan menggabungkan fitur yang paling diskriminatif pada gambar dan dapat melakukan segmentasi 2% lebih baik dibandingkan dengan BiSeNet [8]. *Backbone* dari model yang digunakan pada AIDAN yaitu adalah ResNet-50, dimana model ResNet-50 memiliki performa yang baik untuk tugas secara umum, namun kurang cocok untuk tugas yang kompleks seperti segmentasi citra medis [15].

Berdasarkan hal tersebut, diusulkan modifikasi dari AIDAN dengan menggunakan beberapa model *pretrained deep learning* seperti Xception, ResNet50, dan DenseNet sebagai *backbone* pengganti, dengan tujuan mampu meningkatkan performa dari segmentasi *echocardiography* [8], [16], [17]. Model Xception dan DenseNet dipertimbangkan karena memiliki beberapa keunggulan dibandingkan dengan model ResNet, seperti kesesuaian model Xception untuk tugas yang lebih rumit melalui *depthwise separable convolution* yang mampu menangkap fitur citra yang kompleks, ataupun model DenseNet yang memiliki parameter lebih sedikit namun mampu memberikan performa yang lebih baik pada tugas-tugas yang kompleks seperti pengolahan citra medis. Model Xception dan DenseNet juga memiliki performa yang lebih baik dibandingkan dengan ResNet50 pada studi kasus tertentu [18].

Penelitian ini bertujuan untuk mengimplementasikan metode Dense-AIDAN dalam segmentasi citra *echocardiography*, serta mengembangkan kemampuan dalam memodifikasi metode tersebut guna meningkatkan performa dalam melakukan segmentasi citra *echocardiography*.

2. METODE PENELITIAN

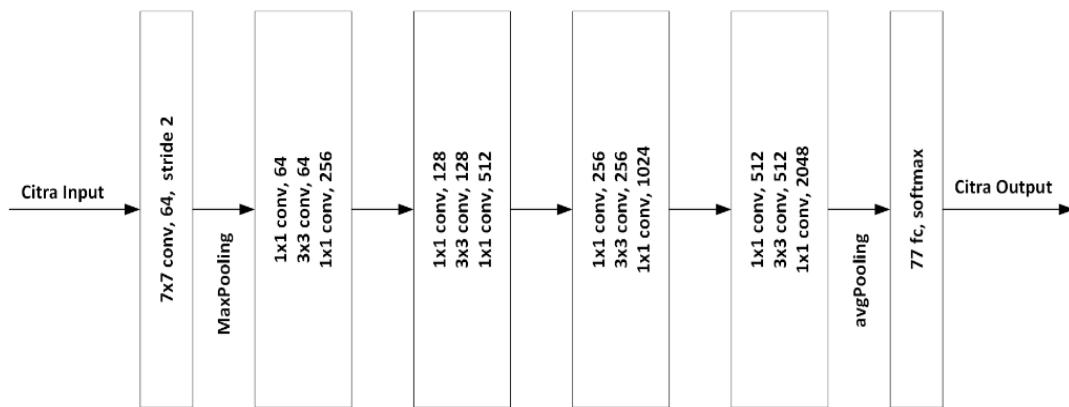
Penelitian dilakukan secara eksperimental, dengan menerapkan *moderate interference* dari peneliti. Penelitian dilakukan dengan menggunakan 4 model *deep learning* yaitu Xception, DenseNet121, dan DenseNet201 sebagai pengganti backbone ResNet50 yang digunakan pada AIDAN. 4 Model ini akan dibandingkan juga dengan metode BiSeNet. Adapun alur penelitian yang digunakan terdapat pada Gambar 1.



Gambar 1. Alur Penelitian

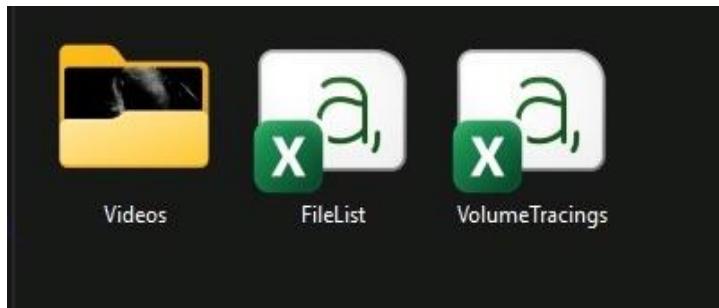
Penelitian dimulai dari studi literatur terkait pencarian dasar teori yang akan digunakan selama penelitian, serta *state of the art* dari penelitian terbaru yang memiliki kemiripan dengan topik penelitian. Tahapan selanjutnya yaitu melaksanakan pencarian dataset, serta melakukan penyesuaian dataset yang telah ditentukan agar dapat digunakan dalam penelitian. Dataset ini kemudian dibagi menjadi data latih, data validasi, dan data uji. Data latih dan data validasi digunakan pada tahap *training* untuk mendapatkan model latih, yang dilanjutkan dengan tahap pengujian yang menggunakan data uji untuk menguji model. Hasil dari pengujian adalah label segmentasi dari citra uji, yang kemudian digunakan sebagai bahan evaluasi terhadap performa model dalam melakukan segmentasi citra.

Terdapat dua kontribusi yang akan didapatkan dari implementasi Dense-AIDAN. Kontribusi pertama adalah pengujian metode BiSeNet dan AIDAN terhadap dataset EchoNet-Dynamic. Kontribusi kedua adalah modifikasi metode dari AIDAN, yakni Dense-AIDAN dalam melakukan segmentasi citra *echocardiography*. DenseNet dipilih karena membutuhkan parameter yang lebih sedikit dibandingkan model *deep learning* lain, sehingga mengurangi kemungkinan *overfitting* dan memberikan performa yang lebih baik dibandingkan dengan model *Residual Network* (ResNet) yang ditunjukkan pada Gambar 2 [19].



Gambar 2. Arsitektur ResNet50

Data yang digunakan pada penelitian adalah dataset publik dari EchoNet-Dynamic[20]. EchoNet-Dynamic merupakan citra *echocardiography* dari 4 ruang jantung. File yang terdapat pada EchoNet-Dynamic ditunjukkan pada Gambar 3. file terpisah seperti yang ditampilkan pada Gambar 3.



Gambar 3. Detail file pada dataset

Gambar 3 menunjukkan sebuah folder video dan 2 file tambahan untuk melengkapi informasi dari dataset yang digunakan. FileList berisikan informasi dataset lebih detail, seperti jumlah frame pada video dan pembagian dataset untuk *benchmarking*. VolumeTracings berisikan informasi terkait volume pemompaan darah yang dilakukan oleh jantung dari video pada dataset.

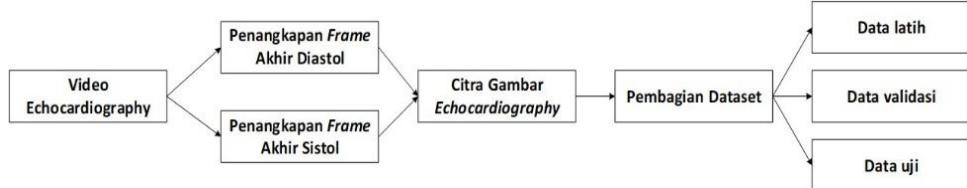
Name	Date	Type	Size	Length
0X1A0A263B22CCD...	8/22/2019 5:24 AM	AVI File	890 KB	00:00:02
0X1A2A76DB5B98...	8/22/2019 5:22 AM	AVI File	654 KB	00:00:04
0X1A2C60147AF9FD...	8/22/2019 5:25 AM	AVI File	858 KB	00:00:03
0X1A2E9496910EFF5B	9/10/2019 9:20 AM	AVI File	566 KB	00:00:03
0X1A3D565B371DC...	8/22/2019 5:22 AM	AVI File	866 KB	00:00:02
0X1A3E7BF1DFB132...	8/22/2019 5:25 AM	AVI File	1,206 KB	00:00:04
0X1A05DFFCABF2...	8/22/2019 5:24 AM	AVI File	1,064 KB	00:00:03
0X1A5FAE3F9D37794E	8/22/2019 5:25 AM	AVI File	858 KB	00:00:02

Gambar 4. Video dari dataset EchoNet-Dynamic

Gambar 4 menunjukkan isi dari folder *Videos* yang ditunjukkan pada Gambar 3. Video echocardiography memiliki resolusi sebesar 112x112 piksel untuk masing-masing video. Terdapat 10.030 video secara keseluruhan yang dipersiapkan dan digunakan sebagai data latih, data validasi, serta data uji. Berdasarkan kerangka penelitian yang telah dipaparkan, metode penelitian yang dilakukan adalah sebagai berikut.

2.1. Persiapan Dataset

Persiapan dataset merupakan proses untuk menyesuaikan dataset yang sudah didapatkan agar dapat digunakan pada penelitian [21]. Dataset dari EchoNet-Dynamic yang didapatkan berupa citra video. Video harus diubah terlebih dahulu menjadi citra gambar.

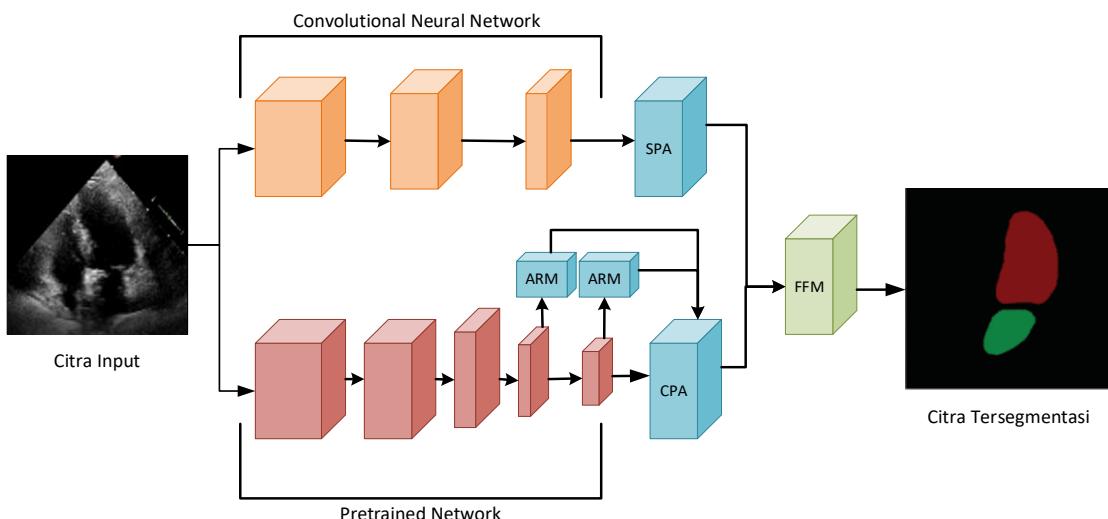


Gambar 5. Persiapan dataset

Gambar 5 menunjukkan alur dari penyiapan dataset secara rinci terdapat pada . Dua *frame* penting diambil dari masing-masing citra video *echocardiography* yang diberikan, yakni pada *frame* saat *end systole* dan *end diastole*. Masing-masing *frame* tersebut dijadikan citra gambar yang kemudian dipisahkan untuk kebutuhan *benchmarking*, menjadi data latih, data validasi, dan data uji.

2.2. Training dan Testing

Training dan *testing* dilakukan dengan menggunakan beberapa *pretrained deep learning* secara bergantian sebagai *backbone* pada AIDAN dan penggunaan *attention refinement module* pada bagian akhir *context path*. *Backbone default* yang digunakan pada AIDAN adalah ResNet50.

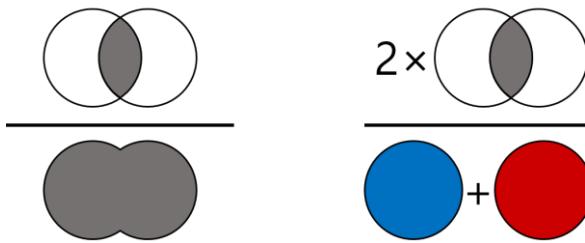


Gambar 6. Model modifikasi AIDAN

Gambar 6 merupakan susunan dari AIDAN yang dimodifikasi. Modifikasi yang dilakukan adalah melakukan penggantian terhadap *backbone* dari AIDAN (blok berwarna merah pada Gambar 6), berdasarkan hasil terbaik dari perbandingan masing-masing model *pretrained deep learning* yang digunakan pada penelitian, yang terdiri dari DenseNet201, DenseNet121, dan Xception [22]. Modifikasi lainnya adalah tetap menggunakan *attention refinement module* pada bagian akhir *context path*.

2.3. Hasil Prediksi dan Evaluasi

Prediksi merupakan proses menentukan kemungkinan terdekat sesuai dengan data serta parameter yang ditentukan dan dimiliki sejak awal [23]. Prediksi yang dihasilkan pada penelitian ini adalah perkiraan segmentasi dari citra uji. Metode evaluasi yang digunakan terhadap hasil dari prediksi segmentasi citra adalah metode *Dice Similarity Coefficient* (DSC) dan *Intersection over Union* (IoU) yang diilustrasikan pada gambar 7.



Gambar 7. (a) IoU dan (b) DSC

DSC merupakan salah satu metrik validasi statistik untuk melakukan evaluasi terhadap akurasi dari hasil segmentasi suatu gambar, yang umumnya digunakan pada citra *magnetic resonance imaging* (MRI) [24]. DSC merupakan nilai hasil dari dua kali jumlah piksel terhadap gambar yang saling tumpang tindih dibagi dengan jumlah piksel dari kedua gambar. Perhitungan DSC sama dengan *F1 score* yang dihitung berdasarkan nilai:

- True Positive (TP), ketika nilai piksel hasil prediksi segmentasi benar, dan positif pada *ground truth*.
- True Negative (TN), ketika nilai piksel hasil prediksi segmentasi salah, dan negatif pada *ground truth*.
- False Positive (FP), ketika nilai piksel hasil prediksi segmentasi benar, dan negatif pada *ground truth*.

Perumusan DSC dapat dilihat pada persamaan (1).

$$DSC = \frac{2TP}{2TP + FN + FP} \quad (1)$$

IoU merupakan metode yang digunakan untuk menghitung kemiripan dari dua buah gambar. IoU dalam deteksi objek dihitung berdasarkan ukuran tinggi, panjang, serta lokasi dari *bounding box* terhadap gambar yang dibandingkan. IoU disebut juga sebagai *Jaccard Indeks* [25]. Perumusan IoU dapat dilihat pada persamaan (2).

$$IoU = \frac{TP}{TP + FN + FP} \quad (2)$$

3. HASIL DAN PEMBAHASAN

Penelitian dilakukan dengan mengambil *frame* video dari dataset yang digunakan. Pengujian dilakukan dengan melakukan perbandingan terhadap metode AIDAN yang menggunakan 4 model *pretrained deep learning* yang terdiri dari Xception, ResNet50, DenseNet121, dan DenseNet201 secara bergantian sebagai *backbone*, dengan tetap menggunakan *attention refinement module* pada akhir *context path*. Perbandingan juga dilakukan terhadap metode BiSeNet, sehingga secara keseluruhan, terdapat 5 model yang dibandingkan berdasarkan nilai DSC dan IoU.

3.1 Persiapan Data

Tujuan dari penelitian adalah melakukan segmentasi terhadap citra gambar dari video *echocardiography* yang terdapat pada dataset EchoNet-Dynamic. Segmentasi citra biomedis umumnya dalam bentuk gambar dengan menggunakan jenis X-Ray, CT, dan MRI [26]. Oleh karena itu, dibutuhkan beberapa tahap persiapan sehingga dataset *echocardiography* yang berbentuk video dapat digunakan dalam penelitian. Terdapat 3 tahapan persiapan data yang dilakukan dalam penelitian, yaitu pembuatan gambar, konversi, dan pembagian dataset untuk keperluan *benchmarking*.

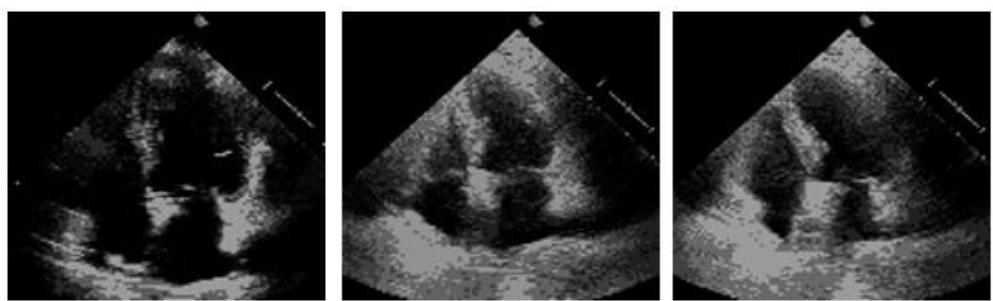
Tahap pertama dalam persiapan data adalah mengambil gambar dari video *echocardiography* dengan menyimpan dua buah *frame* pada video menjadi sebuah gambar dengan format PNG. Dua *frame* yang diambil adalah *frame end systole* dan *frame end diastole*, yang telah disediakan pada *file csv* pelengkap pada dataset EchoNet-Dynamic.



Gambar 8. Gambar Sampel Dari Dataset

Gambar 8 merupakan gambar hasil ekstraksi terhadap video pada dataset EchoNet-Dynamic. Gambar yang diekstrak memiliki ukuran yang sama dengan video, yakni 112x112 piksel, dengan kedalaman 24 bit.

Dataset gambar yang sudah ekstrak kemudian dikonversi menjadi gambar 8 bit. Hal ini dilakukan untuk meningkatkan performa terhadap proses *training* yang akan dilakukan.



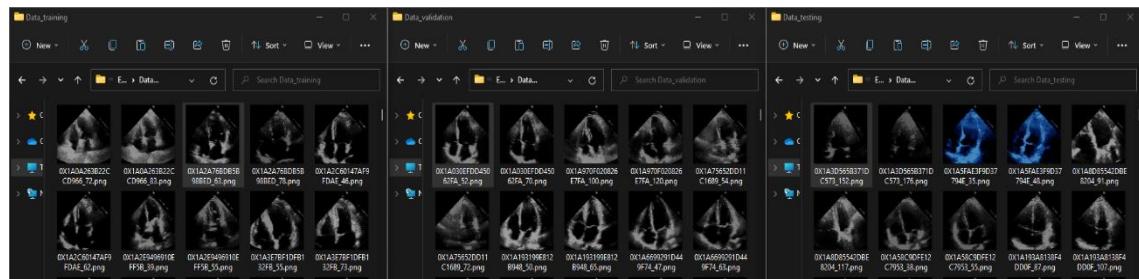
Gambar 9. Hasil Konversi Gambar Menjadi 8 Bit

Gambar 9 merupakan hasil konversi dari dataset gambar yang semula memiliki ukuran 24 bit, yang kemudian dikonversi menjadi gambar 8 bit. Gambar yang sudah dikonversi kemudian dibagi sesuai dengan label kelas yang telah disediakan pada *file csv* EchoNet-Dynamic, dengan pembagian menjadi data latih, data validasi, dan data uji.

Gambar 10 menampilkan hasil dari pembagian dataset. Jumlah gambar dari dataset yang digunakan adalah 14.920 gambar, 2.576 gambar, dan 2.552 gambar untuk data latih, data validasi, dan data uji secara berturut-turut.

3.2 Implementasi Model

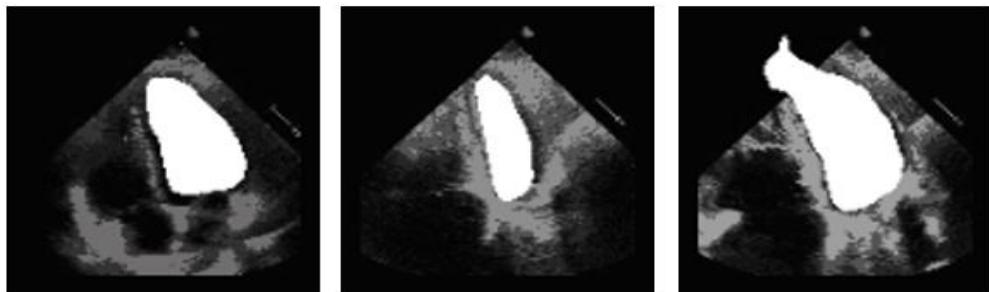
Segmentasi citra *echocardiography* yang dilakukan menggunakan metode modifikasi terhadap AIDAN. Implementasi model dan modifikasi dari AIDAN dilakukan dengan mengubah *backbone* dari AIDAN. Adapun hasil implementasi beberapa *backbone* yang telah diuji pada penelitian adalah sebagai berikut.



Gambar 10. Pembagian Dataset

a. *Exception*

Pengujian pertama adalah penggunaan *backbone* Xception [27] pada bagian *context path*. Pengujian dilakukan dengan menggunakan *learning rate* 0.001, *batch size* 32, dan *epochs* sebanyak 50.

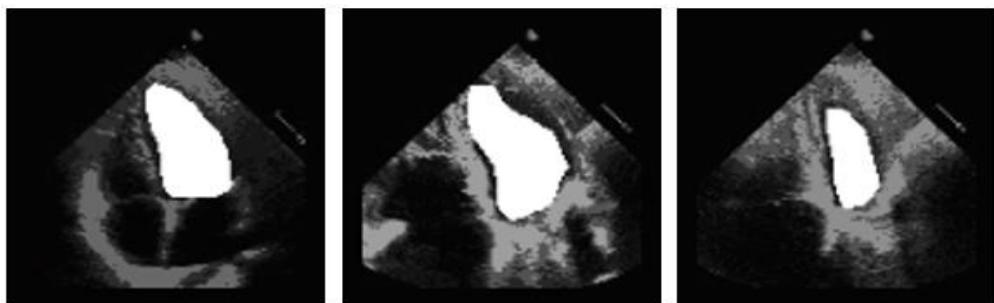


Gambar 11. Hasil Segmentasi Xception

Gambar 11 menampilkan hasil prediksi segmentasi menggunakan *pretrained deep learning* dengan arsitektur Xception. Terdapat beberapa gambar yang tidak berhasil disegmentasi, serta hasil segmentasi yang masih kurang baik secara visual.

b. ResNet50

Pengujian kedua adalah penggunaan *backbone* ResNet50 [28]. *Backbone* ResNet50 merupakan *backbone* yang digunakan pada AIDAN. Pengujian dilakukan dengan parameter yang sama dengan Xception.

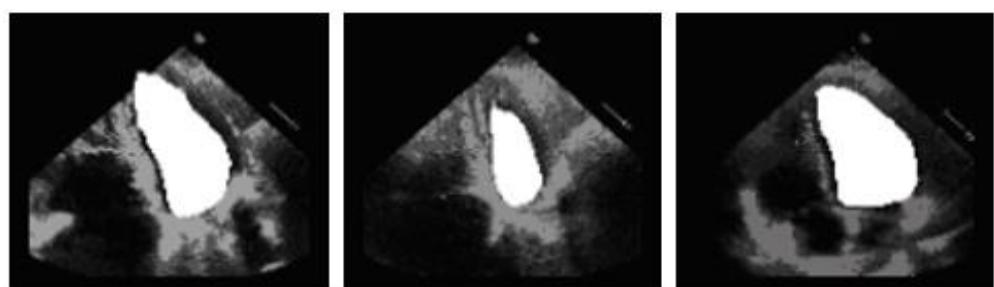


Gambar 12. Hasil Segmentasi ResNet50

Gambar 12 merupakan hasil prediksi segmentasi dengan menggunakan ResNet50 sebagai *backbone* pada *context path*. Hasil yang diberikan mirip dengan penggunaan Xception, dimana terdapat sebagian gambar yang tidak berhasil disegmentasi, serta hasil segmentasi yang kurang baik secara visual.

c. DenseNet121

Pengujian ketiga dilakukan dengan menggunakan DenseNet121 sebagai *backbone*. Terdapat perubahan parameter yang digunakan dalam pengujian ini, yakni perubahan nilai *epoch* menjadi 20.

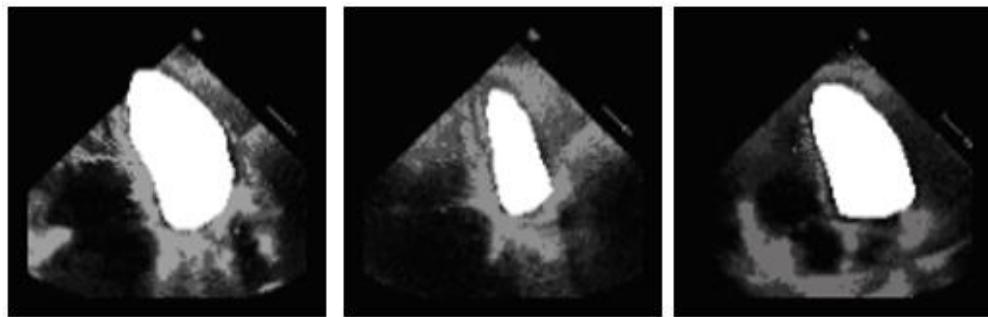


Gambar 13. Hasil Segmentasi DenseNet121

Gambar 13 menampilkan hasil segmentasi dengan *pretrained deep learning* DenseNet121. Hasil yang diberikan mampu memberikan prediksi segmentasi terhadap hampir seluruh data uji yang diberikan. Hanya terdapat beberapa citra yang tidak berhasil disegmentasi.

d. DenseNet201

Pengujian keempat adalah penggunaan DenseNet201 sebagai *backbone*. Parameter yang digunakan sama dengan pengujian dengan *backbone* DenseNet121.

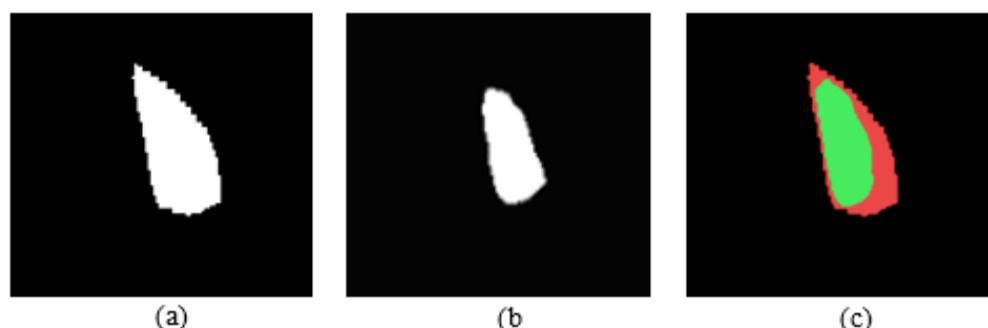


Gambar 14. Hasil Segmentasi DenseNet201

Gambar 14 merupakan hasil prediksi segmentasi dengan menggunakan DenseNet201 sebagai *backbone*. Terdapat sebagian kecil gambar yang tidak berhasil disegmentasi, serta hasil prediksi segmentasi yang diberikan lebih baik secara visual dibandingkan dengan pengujian dengan *backbone* yang telah diuji sebelumnya.

3.3 Hasil Prediksi dan Implementasi

Evaluasi dilakukan dengan cara menghitung terlebih dahulu secara keseluruhan piksel dari seluruh data antara hasil prediksi dengan data sesungguhnya (*ground truth*). Evaluasi dilakukan dengan metode DSC dan IoU.



Gambar 15. (a) *Ground Truth*, (b) Label Hasil Prediksi, (c) *Masking*

Gambar 15 menunjukkan contoh *ground truth*, label segmentasi hasil prediksi, serta *masking* antara label segmentasi hasil prediksi dengan *ground truth*. Label tersebut kemudian digunakan sebagai *mask* pada *ground truth* seperti yang ditunjukkan Gambar 15 (c) dan dibandingkan untuk menghitung nilai DSC dan IoU. Nilai yang digunakan adalah 1 jika benar (*true*), dan 0 jika salah (*false*), dan dihitung berdasarkan:

- 1) *true positive* (hasil prediksi = *ground truth* = 1),
- 2) *false negative* (hasil prediksi = 0 dan *ground truth* = 1), dan
- 3) *false positive* (hasil prediksi = 1 dan *ground truth* = 0).

Nilai dari masing-masing *true positive*, *false negative*, dan *false positive* kemudian digunakan untuk menghitung DSC dan IoU.

Tabel 1. Hasil DSC dan IoU dari Seluruh Model

Model	DSC	IoU
Bisenet	0.7210	0.5637

Model	DSC	IoU
AIDAN	0.7393	0.5865
AIDAN (Xception)	0.8007	0.6676
AIDAN (DenseNet121)	0.7580	0.6104
Dense-AIDAN (DenseNet201)	0.8098	0.6804

Tabel 1 merupakan rincian nilai DSC dan IoU dari hasil pengujian *pretrained deep learning* yang dilakukan dalam penelitian. Dapat dilihat bahwa model Dense-AIDAN, yang merupakan modifikasi AIDAN dengan *backbone* DenseNet201 memberikan hasil DSC dan IoU tertinggi dibandingkan dengan backbone lain, sebesar 0.81 dan 0.68 secara berturut-turut sehingga menjadikan model ini memiliki hasil terbaik dibandingkan dengan model lain yang diimplementasikan.

4. KESIMPULAN DAN SARAN

Penelitian ini mengimplementasikan model Dense-AIDAN yang memiliki hasil segmentasi *echocardiography* yang paling baik dibandingkan dengan ResNet50 dan Xception. Dense-AIDAN memberikan hasil terbaik dengan nilai DSC dan IoU sebesar 0.81 dan 0.68 secara berturut-turut, 12% lebih baik secara keseluruhan dibandingkan dengan AIDAN.

Agar performa model dapat ditingkatkan lebih lanjut, disarankan untuk meningkatkan jumlah variasi data latih agar model latih dapat belajar lebih baik. Data latih dapat ditambahkan dengan menggabungkan beberapa dataset publik ataupun melakukan augmentasi citra sebelum tahap pelatihan dimulai. Model juga masih dapat ditingkatkan dengan melakukan optimalisasi dan *fine-tuning* lebih lanjut pada *attention module* yang terdapat pada akhir dari masing-masing *path* pada model.

DAFTAR PUSTAKA

- [1] D. L. Lestari, “Penyakit Jantung Bawaan pada Anak,” *Scientific Journal*, vol. 2, no. 4, pp. 134–142, 2023.
- [2] S. Y. Parvar, R. Ghaderpanah, and A. Naghshzhan, “Prevalence of congenital heart disease according to the echocardiography findings in 8145 neonates, multicenter study in southern Iran,” *Health Sci. Rep.*, vol. 6, no. 4, 2023, doi: 10.1002/hsr2.1178.
- [3] B. E. Putra and R. Prakoso, “The Importance of Early Detection of Congenital Heart Disease: Prenatal and Postnatal Screening,” *Journal Of The Indonesian Medical Association*, vol. 72, no. 2, pp. 56–58, 2022, doi: 10.47830/jimma-vol.72.2-2022-822.
- [4] S. Omerovic and A. Jain, “Echocardiogram.” Accessed: Nov. 20, 2025. [Online]. Available: <https://www.ncbi.nlm.nih.gov/books/NBK558940/>
- [5] M. Tian and M. Zheng, “A Heart Segmentation Algorithm Based on Dynamic Ultrasound,” *Biomed Res. Int.*, vol. 2022, 2022, doi: 10.1155/2022/1485584.
- [6] N. Nabila and G. T. Putri, “Heart Failure In Congenital Heart Disease,” *Medical Profession Journal of Lampung*, vol. 15, no. 1, pp. 132–138, 2025, doi: 10.53089/medula.v15i1.1461.
- [7] J. Liu *et al.*, “Speckle noise reduction for medical ultrasound images based on cycle-consistent generative adversarial network,” *Biomed. Signal Process. Control*, vol. 86, p. 105150, 2023, doi: <https://doi.org/10.1016/j.bspc.2023.105150>.
- [8] Y. Hu *et al.*, “AIDAN: an attention-guided dual-path network for pediatric echocardiography segmentation,” *Ieee Access*, vol. 8, pp. 29176–29187, 2020.
- [9] C. Urrea and M. Vélez, “Advances in Deep Learning for Semantic Segmentation of Low-Contrast Images: A Systematic Review of Methods, Challenges, and Future Directions,” *Sensors*, vol. 25, no. 7, p. 2043, 2025.
- [10] L. Xu, M. Liu, J. Zhang, and Y. He, “Convolutional-Neural-Network-Based Approach for Segmentation of Apical Four-Chamber View from Fetal Echocardiography,” *IEEE Access*, vol. 8, pp. 80437–80446, 2020, doi: 10.1109/ACCESS.2020.2984630.

- [11] C. Yu, C. Gao, J. Wang, G. Yu, C. Shen, and N. Sang, “BiSeNet V2: Bilateral Network with Guided Aggregation for Real-time Semantic Segmentation,” *CoRR*, vol. abs/2004.02147, 2020, [Online]. Available: <https://arxiv.org/abs/2004.02147>
- [12] M. Fan *et al.*, “Rethinking bisenet for real-time semantic segmentation,” in *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, 2021, pp. 9716–9725.
- [13] S. Zhao, X. Wu, and K. Tian, “Real-time semantic segmentation network based on improved BiSeNet V1,” in *Proceedings of the 2022 11th International Conference on Networks, Communication and Computing*, in ICNCC '22. New York, NY, USA: Association for Computing Machinery, 2023, pp. 38–44. doi: 10.1145/3579895.3579902.
- [14] M. P. Nugraha and L. Rahadiani, “Deep Image Deblurring for Non-Uniform Blur: a Comparative Study of Restormer and BANet,” *Jurnal Ilmu Komputer dan Informasi*, vol. 17, no. 2, pp. 175–183, Jun. 2024, doi: 10.21609/jiki.v17i2.1274.
- [15] T. Chauhan, H. Palivel, and S. Tiwari, “Optimization and fine-tuning of DenseNet model for classification of COVID-19 cases in medical imaging,” *International Journal of Information Management Data Insights*, vol. 1, no. 2, 2021, doi: 10.1016/j.jjimei.2021.100020.
- [16] M. A. Morid, A. Borjali, and G. Del Fiol, “A scoping review of transfer learning research on medical image analysis using ImageNet,” *Comput. Biol. Med.*, vol. 128, p. 104115, 2021.
- [17] M. C. Daniel and L. M. Ruxandra, “Brain tumor classification using pretrained convolutional neural networks,” in *2021 16th International Conference on Engineering of Modern Electric Systems (EMES)*, 2021, pp. 1–4.
- [18] D. Kurniadi, N. P. Nurhaliza, B. B. Balilo Jr, H. Aulawi, and A. Mulyani, “A Comparison Analysis Between ResNET50 and Xception for Handwritten Hangeul Character using Transfer Learning,” *Jurnal Online Informatika*, vol. 10, no. 2, pp. 308–322, 2025, doi: 10.15575/join.v10i2.1606.
- [19] J. R. Sunkara, S. R. Bauskar, C. R. Madhavaram, E. P. Gallia, H. K. Gollangi, and others, “An Evaluation of Medical Image Analysis Using Image Segmentation and Deep Learning Techniques,” *Journal of Artificial Intelligence & Cloud Computing. SRC/JAICC-407. DOI: doi.org/10.47363/JAICC/2023 (2)*, vol. 388, pp. 2849–2857, 2023.
- [20] K. Vidhya, B. Nagarajan, A. Jenefa, R. C. Joy, M. Cherian, and N. F. Kingstein, “EchoNet Dynamic: Deep Learning-driven Advancements in Dynamic Heart Function Analysis through Echocardiography,” in *2025 3rd International Conference on Intelligent Data Communication Technologies and Internet of Things (IDCIoT)*, 2025, pp. 1145–1151. doi: 10.1109/IDCIoT64235.2025.10914862.
- [21] M. F. Rachmadhan, M. H. Umam, A. Wibowo, and I. M. S. Ramayu, “Internet Service Provider User Customer Lifetime Segmentation Analysis using RFM and K-Means Algorithm,” *Sinkron*, vol. 9, no. 1, pp. 306–316, 2024, doi: 10.33395/sinkron.v9i1.13024.
- [22] F. Zhuang *et al.*, “A comprehensive survey on transfer learning,” *Proceedings of the IEEE*, vol. 109, no. 1, pp. 43–76, 2020.
- [23] G. Puspa, M. F. R. Amri, and M. P. Nugraha, “Pemanfaatan Random Forest untuk Prediksi Ketepatan Waktu Kelulusan Mahasiswa Studi Kasus: Institut Desain dan Bisnis Bali,” *JIKO (Jurnal Informatika dan Komputer)*, vol. 9, no. 2, pp. 413–426, 2025.
- [24] D. Müller, I. Soto-Rey, and F. Kramer, “Towards a guideline for evaluation metrics in medical image segmentation,” *BMC Res. Notes*, vol. 15, no. 1, p. 210, 2022.
- [25] D. Ogwok and E. M. Ehlers, “Jaccard Index in Ensemble Image Segmentation: An Approach,” in *Proceedings of the 2022 5th International Conference on Computational Intelligence and Intelligent Systems*, in CIIS '22. New York, NY, USA: Association for Computing Machinery, 2023, pp. 9–14. doi: 10.1145/3581792.3581794.
- [26] I. R. I. Haque and J. Neubert, “Deep learning approaches to biomedical image segmentation,” *Inform. Med. Unlocked*, vol. 18, p. 100297, 2020.

- [27] S. Sharma and S. Kumar, “The Xception model: A potential feature extractor in breast cancer histology images classification,” *ICT Express*, vol. 8, no. 1, pp. 101–108, 2022, doi: <https://doi.org/10.1016/j.icte.2021.11.010>.
- [28] M. Shafiq and Z. Gu, “Deep Residual Learning for Image Recognition: A Survey,” *Applied Sciences*, vol. 12, no. 18, 2022, doi: 10.3390/app12188972.