



Segmentasi Objek Citra Ultrasonografi Terotomatisasi Menggunakan Metode Aktif Kontur Kombinatorial

Automated Ultrasound Object Segmentation Using Combinatorial Active Contour Method

Anan Nugroho^{*1)}, Budi Sunarko²⁾, Hari Wibawanto³⁾, Anggraini Mulwinda⁴⁾, Anas Fauzi⁵⁾, Dwi Oktaviyanti⁶⁾, Dina Wulung Savitri⁷⁾

¹⁻⁷⁾Jurusan Teknik Elektro, Fakultas Teknik, Universitas Negeri Semarang
Gedung E11 Jurusan Teknik Elektro FT UNNES, Kampus Sekaran Gunungpati, Kota Semarang, Indonesia 50229

Cara sitasi: N. P. Pertama and N. P. Kedua, "Segmentasi Objek Citra Ultrasonografi Terotomatisasi Menggunakan Metode Aktif Kontur Kombinatorial mulai penerbitan nomor 6(4) tahun 2018," *Jurnal Teknologi dan Sistem Komputer*, vol. 9, no. x, pp. xx-xx, 2022. doi: [10.14710/jtsiskom.2022.xxxxx](https://doi.org/10.14710/jtsiskom.2022.xxxxx) [Online].

Abstract – Active Contour (AC) is an algorithm widely used in segmentation for developing Computer-Aided Diagnosis (CAD) systems in ultrasound imaging. However, the existing methods are still interactive, which can result in human error and various issues caused by the inhomogeneity of ultrasound images, such as leakage, false areas, and local minima. In this study, an automatic object segmentation method was developed to assist radiologists in an efficient diagnosis process. The proposed method is called Automatic Combinatorial Active Contour (ACAC), which combines the simplification of the global region-based CV (Chan-Vese) model and improved-GAC (Geodesic Active Contour) for local segmentation. The results of testing with 50 datasets showed an accuracy value of 98.83%, precision of 95.26%, sensitivity of 86.58%, specificity of 99.63%, similarity of 90.58%, and IoU (Intersection over Union) of 82.87%. These quantitative performance metrics demonstrate that the ACAC method is suitable for implementation in a more efficient and accurate CAD system.

Keywords – active contour; automated; combinatorial; CAD; segmentation; USG

Abstrak – Active Contour (AC) merupakan algoritme yang banyak digunakan dalam melakukan segmentasi dalam mengembangkan sistem Computer Aided Diagnosis (CAD) pada pencitraan USG. Namun metode yang berkembang masih bersifat interaktif yang menyebabkan human error serta adanya berbagai masalah akibat inhomogenitas pada citra Ultrasonografi (USG) seperti leakage, terjadinya false area serta local minima. Pada studi ini dikembangkan metode segmentasi objek otomatis pada citra USG untuk membantu radiolog dalam proses diagnosis yang efisien. Metode yang dikembangkan disebut Automatic Combinatorial Active Contour (ACAC) yang mengkombinasikan turunan simplifikasi model global

region-based CV (Chan-Vese) dan improved-GAC (Geodesic Active Contour) untuk segmentasi lokal. Hasil studi dengan 50 dataset yang diuji coba yaitu didapatkannya nilai accuracy sebesar 98.83%, precision 95.26%, sensitivity 86.58%, specificity 99.63%, similarity 90.58%, dan IoU 82.87%. performa kuantitatif ini membuktikan bahwa metode ACAC layak diimplementasikan pada sistem CAD yang lebih efisien dan akurat.

Kata kunci – Aktif kontur; otomatis; kombinatorial; CAD; segmentasi; USG

I. PENDAHULUAN

Ultrasonografi (USG) merupakan modalitas pencitraan medis yang paling banyak digunakan untuk skrining kelainan kelenjar dan jaringan karena murah, non-invasif, dan mudah digunakan [1]. Kemampuan USG dalam menghasilkan hasil citra secara *real-time* dan cepat membuat USG sangat efisien untuk pemeriksaan skala besar dan dilakukan secara berulang. Keterlibatan USG dalam radiologi terlihat dalam pemeriksaan jantung, payudara, tiroid, prostat, ginjal, dan hati [2]. Utamanya, USG secara intensif digunakan dalam penilaian kanker payudara dan tiroid. Kedua kanker ini memiliki karakteristik keganasan yang serupa dan dalam beberapa penelitian menyatakan keduanya saling berkaitan [3]–[5]. Lesi payudara dan nodul tiroid merupakan dua objek kanker yang menjadi perhatian utama penyelidikan dalam studi ini.

Terlepas dari semua kelebihan yang dimilikinya, interpretasi citra USG bersifat subjektif karena sangat tergantung pada keahlian, keterampilan, dan pengalaman ahli radiolog sehingga mengakibatkan tingginya variabilitas dalam proses diagnosis [6]. Kualitas USG yang kurang memadai, seperti resolusi yang buruk atau kontras yang rendah, menambah rumitnya analisis visual dan memperbesar potensi salah interpretasi [7]. Dengan mengadopsi sejumlah algoritme pengolahan citra dan pengenalan pola, teknologi *Computer Aided Diagnosis* (CAD) telah berkembang pesat untuk mengatasi masalah

^{*}) Corresponding author (Anan Nugroho)
Email: anannugroho@mail.unnes.ac.id



tersebut [8]. CAD bertujuan untuk memberikan informasi yang objektif bagi radiolog sebagai pertimbangan tambahan dalam mendukung diagnosis. Tahapan proses diagnosis pada sistem CAD dimulai dari tahap akuisisi citra, *preprocessing*, segmentasi, ekstraksi fitur, dan klasifikasi hingga mendapatkan hasil diagnosis yang akurat [9].

Segmentasi dalam sistem CAD memiliki peranan yang penting untuk memisahkan lesi dan nodul dengan tepat dari jaringan sekitarnya [10]. Tantangan muncul ketika karakter citra USG memiliki inhomogenitas yaitu distribusi intensitas tekstur yang tidak seragam dengan keaburan tepi objek sehingga mempersulit proses segmentasi. Komplikasi ini disebabkan oleh pengaruh *speckle noise* dan adanya berbagai *artifact* pada citra USG. *Speckle noise* merupakan penyebab utama objek tampak kabur dan batas tidak jelas [11]. Sedangkan *artifact* adalah cacat piksel akibat penambahan atribut deskripsi secara manual oleh mesin atau operator seperti teks, notasi, garis atau simbol [12].

Keterampilan manusia sangat mumpuni dan penuh kehati-hatian dalam melakukan pemilahan objek kanker citra USG. Tetapi, untuk jumlah citra USG yang banyak, aktivitas manual ini tidak praktis dan beresiko pada *human error*. Kebutuhan reprodutifitas tinggi dan efisiensi menuntut inovasi teknik segmentasi USG yang otomatis. Saat ini, berbagai metode segmentasi tersedia secara luas. Masing-masing memiliki relevansi dengan objek segmentasinya sendiri dan tidak ada yang lebih unggul dalam semua kasus. Tidak ada metode segmentasi yang dapat bekerja secara adekuat di semua jenis citra [13]. Selain itu, semua metode umumnya sudah mapan-permanen atau *unmodifiable* sehingga tidak mendukung untuk pengembangan aplikasi praktis yang mensyaratkan fleksibilitas parameter. Oleh karena itu, studi ini bertujuan untuk mengatasi masalah tersebut melalui pengembangan metode segmentasi otomatis yang adaptif.

Di antara metode yang ada, model *Active Contour* (AC) yang variatif merupakan pendekatan efisien yang dapat dikembangkan sebagai teknik segmentasi untuk kepentingan khusus di citra USG [14]. Survei dari beberapa penelitian [15]–[21] menunjukkan bahwa model AC yang dapat diubah merupakan pendekatan yang paling banyak diterapkan dalam segmentasi citra USG. AC merupakan kurva dinamis yang berkembang dalam bidang normal gambar dan berhenti pada gradien tepi atau pada batas perubahan intensitas. AC dapat melakukan segmentasi objek tertentu tanpa memerlukan tahapan *preprocessing* yang lama. Dengan kemampuan tersebut, AC sangat kuat untuk berbagai macam aplikasi. Metode ini dibangun berdasarkan model matematis yang melibatkan parameter dan variabel yang dapat disesuaikan sehingga berpeluang untuk dijadikan sebagai teknik segmentasi otomatis.

Namun, model AC yang ada masih bersifat interaktif. Hal ini disebabkan banyaknya parameter dan koefisien yang perlu diatur manual untuk mencapai stabilitas. Model AC yang stabil dicirikan oleh tren konvergen dalam perubahan panjang (*length*) dan luas (*area*) kurva


selama proses evolusi. Konvergensi adalah kemampuan model AC untuk berhenti tepat pada segmentasi target objek yang diharapkan. Semakin konvergen, model AC akan semakin andal dan tangguh. Namun, banyaknya parameter atau koefisien yang terlibat dalam model AC akan meningkatkan intervensi operator sehingga tidak praktis. Proses segmentasi menjadi kompleks dan sulit.

Adanya inhomogenitas pada citra USG berdampak negatif pada evolusi sehingga kurva terjebak pada *false area* (FA) atau daerah palsu yang bukan merupakan objek target segmentasi namun malah tersegmentasi seperti yang ditunjukkan pada Gambar 1. Inhomogenitas juga menghasilkan masalah *leakage* (kebocoran) dalam evolusi kurva AC seperti yang ditunjukkan pada Gambar 2. *Leakage* merupakan istilah untuk evolusi kurva yang menembus atau menabrak batas objek karena gradien tepi yang lemah atau kaburnya intensitas antara objek dan latar belakangnya. Pada kondisi *noise* yang parah, bahkan kurva AC tidak dapat bergerak sama sekali karena terjebak dalam area *local minima* (LM) seperti yang diilustrasikan pada Gambar 3. LM merupakan area yang sulit dideteksi dengan adanya gradien di sekitar tepi sehingga tidak dapat dibedakan antara objek target dan *background*. LM adalah kondisi kebalikan dari *leakage* dalam fenomena evolusi AC.


Terdapat banyak penelitian yang menerapkan berbagai metode segmentasi terhadap citra medis terutama USG dengan metode AC yang saat ini banyak dikembangkan [21]–[28]. Di antara metode AC tersebut adalah *Chan-Vese* (CV) berbasis wilayah [29] dan *Geodesic Active Contour* (GAC) berbasis tepi yang merupakan dua metode dasar AC [30].



Gambar 1. Problem segmentasi AC *False Area* (FA).



Gambar 2. Problem segmentasi AC *Leakage*.




Gambar 3. Problem segmentasi AC *Local Minima*.

II. STUDI LITERATUR

Penerapan AC sebagai metode segmentasi pada citra USG masih memiliki kendala. Formulasi yang dikembangkan saat ini masih melibatkan banyak parameter dan koefisien yang kompleks untuk mencapai stabilitas. Penyesuaian parameter dan koefisien pada model AC masih *trial and error*. Metode AC yang ada juga membutuhkan *initial* kontur manual yang interaktif dan belum mampu beradaptasi dengan input citra USG sehingga intervensi manusia masih dominan [31]. Tingkat intervensi manusia yang tinggi dalam model AC menjadikannya tidak praktis dalam implementasi. Penerapannya di CAD akan menghasilkan nilai subjektivitas dan variabilitas diagnosis yang tinggi di antara pengguna. Implementasi dalam segmentasi skala besar, terus menerus dan berulang kali meningkatkan *human error*. Hal ini tentu kontra dari tujuan. Adanya *speckle noise* dan berbagai *artifact* pada citra USG berdampak inhomogenitas yang menyebabkan evolusi AC jatuh pada FA, *leakage*, dan LM [30]. Faktor-faktor tersebut menjadi penyebab utama rendahnya akurasi dalam segmentasi objek radiologi USG.

Penelitian Nugroho, dkk., 2020 berhasil menciptakan algoritme segmentasi akurat dengan mengkombinasikan model AC *hybrid* berbasis *region-edge* dengan peningkatan filter bilateral (BF) yang disebut *active contour bilateral filter* (ACBF) pada citra USG [31]. ACBF secara optimal menggabungkan keunggulan metode BF, GAC, dan CV. Hasil dari penelitian tersebut membuktikan bahwa dengan metode *hybrid-AC* dan ACBF memiliki skor DC (*dice coefficient*) tertinggi dan waktu komputasi yang singkat. Hal tersebut karena keduanya mampu mencapai konvergensi sementara metode GACV yang dikomparasikan gagal. Waktu komputasi lebih ditentukan oleh seberapa besar objek yang akan disegmentasi. Manfaat utama ACBF adalah dapat secara efektif menggambarkan beberapa lesi pada citra dengan *speckle noise* yang parah [31]. Hasil penelitian ACBF terlihat pada Gambar 4.



Gambar 4. Hasil segmentasi metode (m)–(p) GACV; (q)–(t) *hybrid-AC*; dan (u)–(x) ACBF.

Berdasarkan hasil di atas, metode CV dapat diterapkan untuk mensegmentasi objek pada citra USG. Namun objek yang tersegmentasi menyebar dikarenakan CV berbasis global sehingga objek-objek kecil disekitar objek target ikut terdeteksi. Maka dari itu, diperlukan metode tambahan, dalam hal ini yaitu metode GAC berbasis regional dengan menambahkan inisial kontur sehingga objek dapat tersegmentasi tepat pada target. Gabungan kedua metode tersebut dinamakan GACV (GAC + CV). Namun GACV memiliki kekurangan yaitu perlu menentukan parameter sehingga tidak efektif akibat adanya intervensi manusia. Oleh karena ini, diperlukan suatu pengembangan metode GACV yang merupakan bagian dari teknik AC. Metode yang diusulkan pada studi ini dinamakan *Automatic Combinatorial Active Contour* (ACAC). Pengembangan metode dalam studi ini difokuskan untuk melakukan segmentasi objek medis pada citra USG serta pengembangan metode ini juga hanya difokuskan pada otomatisasi dan peningkatan akurasi metode.

III. METODE PENELITIAN

Pada studi ini, data objek kanker pada citra USG sebanyak 50 citra USG radiologi payudara dan tiroid yang diperoleh dari Departemen Radiologi, Rumah Sakit Umum Pusat (RSUP) Dr. Sardjito dan Rumah Sakit Pusat Angkatan Udara (RSPAU) dr. Suhardi Hardjolukito Yogyakarta, Indonesia dengan ekstensi *.png* beserta *ground truth* yang dapat digunakan untuk validasi pengujian terhadap hasil segmentasi citra yang dihasilkan melalui program Python. Program ini dibuat menggunakan bantuan *library Scikit-Image* sebagai pengolahan citra, dan *Numpy* untuk perhitungan *array* matematis. Selanjutnya program diuji dan divalidasi menggunakan metode *confusion matrix*.

A. Metode Segmentasi ACAC

Caselles memperkenalkan model deteksi tepi yang merupakan pengembangan dari model *Active contour* (*snake*) yaitu model GAC yang menggambarkan fungsi energi yang terdiri dari dua komponen yaitu energi internal dan energi eksternal [32]. Energi internal

berfungsi untuk mengontrol kehalusan kurva, sedangkan energi eksternal untuk menarik kurva ke arah batas objek.

Keuntungan penggunaan evolusi GAC adalah kemampuannya untuk dapat melakukan lokalisasi segmentasi lesi secara spesifik. Namun masalah *leakage* dan *local minima* rentan terjadi pada model GAC. Sedangkan CV merupakan metode segmentasi global yang didasarkan pada masalah minimalisasi energi. CV diformulasikan dalam konsep *level set*, yang mengarah ke cara yang lebih mudah untuk menyelesaikan masalah segmentasi. Metode ini banyak diterapkan pada citra yang perlu disegmentasi menjadi dua wilayah yaitu objek target dan latar belakang [33]. Karena pada prinsipnya CV bekerja dengan memisahkan *background* dan *foreground* berdasarkan rerata nilai intensitas secara simultan di keseluruhan piksel [34].

ACAC merupakan metode yang dikembangkan dalam studi ini untuk melakukan segmentasi otomatis pada citra USG. Metode ini mengkombinasikan turunan simplifikasi model *global region-based CV* dengan melakukan *robust binary stopping function* (BSF) dan *improved-GAC* untuk segmentasi lokal dengan evolusi kontur yang akurat. Otomatisasi diterapkan pada deteksi objek untuk membentuk BSF yang menghasilkan inisial kontur hasil dari simplifikasi formulasi CV.

Segmentasi citra USG melalui metode ACAC dimulai dengan pembentukan BSF menggunakan simplifikasi CV kemudian dilanjutkan dengan lokalisasi objek target menggunakan GAC. ACAC menggabungkan CV yang telah tersimplifikasi dalam Persamaan (1) dengan model GAC pada Persamaan (2).

$$\frac{\partial \phi}{\partial t} = \left[\text{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) + [I - 0.5(c_1 + c_2)] \delta(\phi) \right] \quad (1)$$

$$\frac{\partial \phi}{\partial t} = \left[\text{div} \left(g \frac{\nabla \phi}{|\nabla \phi|} \right) + v g \right] \quad (2)$$

Keterangan : ϕ = fungsi *level set*

t = variabel waktu

div = operasi divergensi

∇ = fungsi gradien spasial

I = citra input

c_1 = nilai rerata piksel di dalam kontur

c_2 = nilai rerata piksel di luar kontur

δ = fungsi *dirac*

g = ESF (*Edge Stopping Function*)

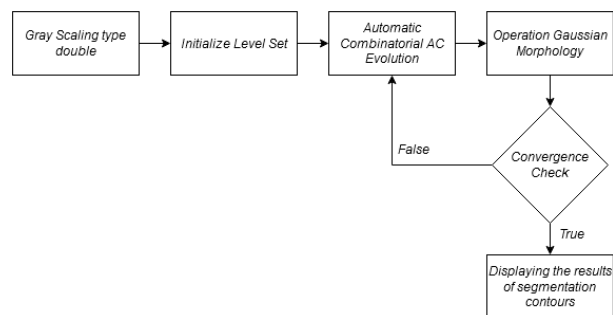
v = kecepatan konstan

Dari kedua persamaan tersebut diperoleh formulasi ACAC yang ditunjukkan oleh Persamaan (3).

$$\frac{\partial \phi}{\partial t} = \left\{ \text{div} \left(\kappa \frac{\nabla \phi}{|\nabla \phi|} \right) + (1 - |\alpha|) \left[I - \frac{c_1 + c_2}{2} \right] + \alpha \kappa \right\} |\nabla \phi| \quad (3)$$

Keterangan : κ = *curvature*

Proses utama dalam metode ACAC ditunjukkan oleh Gambar 5.



Gambar 5. Tahapan metode ACAC.

Grayscale


Merupakan tahapan awal untuk mengubah data setiap piksel pada citra USG menjadi satu kanal yang memiliki nilai antara 1-225 dengan tipe data *float* (tipe data yang dapat menyimpan nilai desimal dan negatif) berdasarkan tingkat intensitas cahaya pada citra.

Inisialisasi Level set

Merupakan proses menginisialisasi letak titik awal evolusi kurva pada citra USG. Letak inisialisasi merupakan pertengahan pada citra yang akan dideteksi sehingga membutuhkan parameter lebar dan tinggi pada citra $I(x,y)$. Pada tahapan ini akan dihasilkan citra biner (citra dengan 2 nilai intensitas saja yaitu 0 dan 1).

Proses Evolusi ACAC

Merupakan serangkaian proses evolusi dengan mengimplementasikan formulasi ACAC dalam Persamaan (3). Proses evolusi di tahap ini diilustrasikan pada Gambar 6.



Gambar 6. Proses evolusi ACAC

Pada dasarnya, metode CV adalah metode segmentasi global, yang berarti kontur awal dapat ditempatkan di mana saja dalam bidang citra. Metode CV akan secara otomatis mengembangkan kontur, tanpa memperhatikan lokasi spesifik kontur awal. Metode ACAC dirancang untuk beroperasi secara otomatis tanpa penyesuaian manual, menghasilkan persamaan evolusi *level set* yang ditunjukkan oleh Persamaan (4).


$$\frac{\partial \phi}{\partial t} = \left(I - \frac{c_1 + c_2}{2} \right) \quad (4)$$

Di mana konstan c_1 mewakili intensitas rata-rata di dalam kurva, dan c_2 mewakili intensitas rata-rata di luar kurva, yang dapat diperoleh melalui Persamaan (5).

$$\begin{cases} c_1(\phi) = \frac{\iint I(x,y) \cdot H(\phi) \, dx dy}{\iint H(\phi) \, dx dy}, \phi < 0 \\ c_2(\phi) = \frac{\iint I(x,y) \cdot (1 - H(\phi)) \, dx dy}{\iint (1 - H(\phi)) \, dx dy}, \phi > 0 \end{cases} \quad (5)$$

$H(\phi)$ adalah fungsi *Heaviside* yang dirumuskan dalam Persamaan (6).

$$H(\phi) = \frac{1}{\pi} \tan^{-1}(\phi) + 0.5 \quad (6)$$



Gambar 7. Ilustrasi (a) evolusi global dan (b) evolusi lokal [35].

Pada Persamaan (3), parameter κ dan α memiliki peranan untuk mengendalikan perubahan antara evolusi global menuju lokal (*switching control*). Evolusi metode ACAC dilakukan melalui dua tahap evolusi. Pertama, evolusi global dilakukan untuk mendeteksi semua objek dalam citra secara otomatis di mana pun letak inialisasi berada sebagaimana terlihat dalam Gambar 7(a) dengan kontur hijau merupakan inisial kontur dan kontur kuning merupakan kontur final. Kedua, evolusi lokal dilakukan untuk segmentasi objek secara lebih spesifik. Masing-masing hasil dari evolusi global dan lokal akan dilakukan pengecekan konvergensi yang didahului tahap operasi morfologi.

Operasi Morfologi Gaussian

Pada metode ACAC, dilakukan dua operasi morfologi, yaitu *opening* dan *closing*. Dua operasi ini dikonvolusi dengan *kernel* Gaussian untuk menekan *artifact* dan *speckle*, sehingga secara efektif mencegah *leakage*, LM, dan FA. Pada segmentasi citra USG, penggunaan filter Gaussian dimaksudkan untuk memberikan efek *smoothing* sehingga menekan *artifact* dan *speckle*. Proses ini juga membantu percepatan konvergensi evolusi. Dengan *opening* dan *closing* yang berurutan ini, *foreground* kecil tidak dipertimbangkan dalam proses segmentasi dan oleh karena itu algoritme ACAC menjadi kokoh terhadap citra *noise* tinggi. Morfologi Gaussian ini memberikan keuntungan untuk menekan *artifact* dan *speckle* sehingga inhomogenitas citra USG dapat diatasi. Tahap ini merupakan proses regularisasi yang juga berfungsi untuk meniadakan prapemrosesan citra sehingga CAD bekerja dengan tahapan yang lebih singkat dan efisien.

Pengecekan Konvergensi

Konvergensi merupakan parameter evolusi AC yang menunjukkan *error* yang mengecil dan mengarah pada berhentinya kontur di target segmentasi yang diharapkan. Mekanisme konvergensi sebagai kendali ESC (*Evolution Stopping Criterion*) diterapkan sehingga metode bersifat otomatis dengan didasarkan kriteria Persamaan (7) dan Persamaan (8). Dengan cara tersebut, peralihan tahap segmentasi dari global ke lokal dapat berjalan secara otomatis. Jika kondisi konvergen belum tercapai maka tahap evolusi ACAC akan masih berulang.

$$Error \ Length = Length(\phi^{i+1}) - Length(\phi^i) \leq \theta \quad (7)$$

$$Error \ Area = Area(\phi^{i+1}) - Area(\phi^i) \leq \theta \quad (8)$$


Menampilkan hasil kontur segmentasi

Setelah hasil sudah konvergen, maka akan ditampilkan kontur hasil segmentasi untuk selanjutnya diuji dan dianalisis performanya.

B. Metode Pengujian dan Validasi

Metode pengujian dan validasi yang digunakan dalam studi ini yaitu *confusion matrix*. *Confusion matrix* menyajikan informasi tentang seberapa sering perilaku tertentu terdeteksi dengan benar dan seberapa sering diklasifikasikan sebagai perilaku lain [36]. Metode analisis data ini digunakan untuk membandingkan hasil segmentasi otomatis objek kanker dengan *ground truth* manual yang dibuat oleh pakar radiolog. Studi ini menggunakan tujuh 7 indikator yang meliputi: tingkat *accuracy*, *precision*, *sensitivity*, *specificity*, *similarity*, nilai *Intersection of Union* (IoU) sebagaimana Persamaan (9)-(14), serta CPU-Time.

Gambar 8 menunjukkan ilustrasi hasil segmentasi objek yang ditandai warna merah, sedangkan untuk *ground truth* ditandai dengan warna hijau yang saling tumpang tindih (*overlapping*) sehingga didapatkan nilai TP, TN, FP dan FN yang digunakan untuk validasi pengujian Persamaan (9)-(13). Nilai persentase *accuracy*, *precision*, *sensitivity*, *specificity*, dan *similarity* yang tinggi menandakan bahwa kontur segmentasi sangat cocok dengan *ground truth*.



Gambar 8. Pengujian menggunakan *confusion matrix*.

$$Accuracy = \frac{|TP+TN|}{|TP+FP+FN+TN|} \times 100\% \quad (9)$$

$$Precision = \frac{|TP|}{|TP+FP|} \times 100\% \quad (10)$$

$$Sensitivity = \frac{|TP|}{|TP+FN|} \times 100\% \quad (11)$$

$$Specificity = \frac{|TN|}{|TN+FP|} \times 100\% \quad (12)$$

$$Similarity = \frac{|2TP|}{|2TP+FP+FN|} \times 100\% \quad (13)$$

Adapun IoU (*Intersection over Union*) adalah area tumpang tindih antara segmentasi yang diprediksi dan *ground truth* dibagi dengan luas gabungan (*union*) antara segmentasi yang diprediksi dan *ground truth*. Persamaan (14) menunjukkan perhitungan IoU.


$$IoU = \frac{TP}{FN + TP + FP} \times 100\% \quad (14)$$

Sedangkan *CPU-Time* (atau *CPU-usage, running time*) adalah jumlah waktu yang dibutuhkan CPU untuk memproses instruksi program komputer (waktu operasi input/output (I/O)).

Pengujian dilakukan dengan pembuatan program khusus berbasis Python untuk mendapatkan selisih jumlah piksel hasil *ground truth* secara manual dengan hasil metode ACAC yang diusulkan. Piksel pada citra *biner* hasil segmentasi metode ACAC dihitung dengan memanfaatkan *library* NumPy dan OpenCV yang selanjutnya dioperasikan sesuai Persamaan (9)-(14).

VI. HASIL DAN PEMBAHASAN

Pada studi ini, dataset kanker yang diperoleh merupakan citra dengan 256 *gray-level depth*. Dataset lesi ini secara klinis dilabeli oleh radiolog dan disegmentasi manual sebagai *ground truth*. Dataset yang dikumpulkan memiliki bentuk nodul atau lesi yang cukup beragam. Dalam satu citra terdapat satu atau lebih nodul atau lesi yang terdeteksi. Salah satu dataset yang digunakan terlihat pada Gambar 9.




Gambar 9. Contoh dataset citra USG.

Selanjutnya usulan algoritme ACAC akan diterapkan pada citra USG. Metode ini akan secara otomatis

mendeteksi di mana letak kanker berada menggunakan inialisasi *level set*. Letak awal *level set* akan mendeteksi panjang dan lebar dari objek kanker, kemudian *level set* akan semakin menyusut mengikuti bentuk lekukan objek kanker tersebut (*shrinking*). Proses ini meminimalisasi *local minima* dan *leakage* pada objek berbatas tepi yang lemah.

Tahapan awal sebelum dilakukan pengolahan citra (*preprocessing*) adalah *grayscale* dengan mengubah data setiap piksel dalam citra menjadi satu kanal yang memiliki nilai 0-255 berdasarkan tingkat intensitas cahaya yang dimiliki. Kemudian dilakukan inialisasi *level set* untuk menginisialisasi letak titik awal evolusi kurva pada sebuah citra. Letak inialisasi merupakan pertengahan pada citra yang akan dideteksi sehingga membutuhkan parameter lebar dan tinggi pada citra $I(x,y)$ seperti pada Gambar 10. Dengan warna putih memiliki nilai 1, dan hitam memiliki nilai 0.




Gambar 10. Inialisasi *level set*.

Selanjutnya dilakukan regularisasi algoritme ACAC. Dengan memanfaatkan simplifikasi CV untuk melakukan segmentasi global, hasil regulasi menghasilkan *bounding box* yang berfungsi sebagai deteksi lokasi kanker. Sebelum menghasilkan *bounding box* tersebut, regularisasi dimulai dengan mengaplikasikan rumus ACAC pada program sehingga menghasilkan citra pada Gambar 11.




Gambar 11. Hasil regularisasi citra sampel dengan metode ACAC.

Selanjutnya dilakukan prosedur binarisasi menggunakan operasi morfologi Gaussian, dilanjutkan dengan operasi morfologi *opening, clear border*, dan *filling holes*. Serangkaian operasi morfologi tersebut dilakukan di antaranya untuk mengurangi *noise* pada citra dan prosedur binarisasi dilakukan sehingga diperoleh hasil pengolahan citra seperti pada Gambar 12.



Gambar 12. Hasil *binary Gaussian* pada sampel citra input.

Setelah semua objek pada citra terdeteksi, dilakukan labelisasi kepada setiap piksel yang saling terhubung sehingga membentuk objek yang diduga kanker untuk memperoleh informasi properti wilayah pada setiap objek (*region props*). Setiap objek yang diduga sebagai kanker diberikan penanda berupa kotak *bounding box* dengan toleransi 20 piksel pada setiap titik sudut kotak seperti terlihat pada Gambar 13 yang mana juga menunjukkan hasil dari proses iterasi pertama.




Gambar 13. Hasil deteksi objek kanker pada sampel citra input.

Setelah objek kanker terdeteksi oleh *bounding box*, selanjutnya dilakukan iterasi dilanjutkan menerapkan metode *improved-GAC* dalam melakukan segmentasi lokal yang akurat. *Bounding box* (kontur berwarna merah) yang merupakan inisial *level set* kemudian mensegmentasi objek menggunakan mode *shrinking* (tren kontur menyusut) menyesuaikan Persamaan (15).


$$\kappa \begin{cases} H(\phi) & \text{expanding GAC, } v < 0 \text{ and } C_0 \\ 1 - H(\phi) & \text{shrinking GAC, } v > 0 \text{ and } C_0 \end{cases} \quad (15)$$

Proses iterasi akan terus dilakukan hingga *level set* mendekati nilai 0. Jika sudah dalam kondisi tersebut, iterasi akan berhenti dan proses segmentasi berakhir. Hasil segmentasi dengan sampel input citra di atas ditunjukkan oleh Gambar 14.



Gambar 14. Hasil segmentasi objek kanker pada sampel citra input.

Dalam menguji seberapa efektif metode ACAC dalam segmentasi objek diukur berdasarkan nilai objek yang saling tumpang tindih antara hasil segmentasi otomatis dengan *ground truth* yang dibuat secara manual oleh pakar radiolog. Area tumpang tindih tersebut akan menunjukkan nilai TP, TN, FP, dan FN. Bentuk area untuk setiap nilai tersebut diilustrasikan pada Gambar 15.



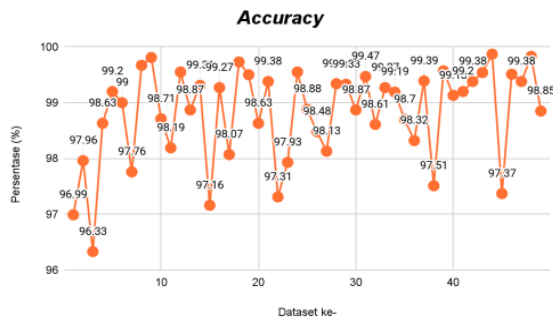
Gambar 15. Gambar hasil pengujian dengan *confusion matrix* pada sampel citra USG.

Gambar 15 menunjukkan delapan visualisasi berbeda dari nilai *confusion matrix* yang digunakan. BW merupakan citra hasil segmentasi otomatis menggunakan metode ACAC. GT merupakan citra *ground truth* yang dibuat secara manual. SA merupakan area gabungan antara BW dengan GT. TP (*True Positive*) adalah area $BW \cap GT$, sedangkan TN (*True Negative*) adalah $\sim BW \cap \sim GT$. FN (*False Negative*) adalah $\sim BW \cap GT$, FP (*False Positive*) adalah $BW \cap \sim GT$, dan FA berbanding terbalik dengan SA. Nilai *confusion matrix* diperoleh dari jumlah piksel area citra yang berwarna putih.


Berdasarkan nilai tersebut didapatkan beberapa perhitungan menggunakan Persamaan (9)-(14) untuk memvalidasi pengujian berdasarkan indikator uji yang telah ditentukan. Setiap dataset akan memiliki nilai *accuracy*, *precision*, *sensitivity*, *specificity*, *similarity*, IoU dan CPU-time yang digunakan untuk mengetahui seberapa cepat proses segmentasi otomatis pada citra USG.

Gambar 16 s.d. Gambar 22 menunjukkan grafik hasil pengujian masing-masing indikator uji untuk 50 dataset. Di mana persentase *accuracy* terendah yaitu 96,33% dan tertinggi yaitu 99,94%. Persentase *precision* terendah berada di angka 86,47% dan tertinggi 99,78%. *Sensitivity* terendah yaitu 75,06% dan tertinggi 95,9%. *Specificity* berada pada jangkauan antara 97,17% hingga 100%. Persentase *similarity* terendah yaitu 84,91% dan tertinggi yaitu 95,42%. Serta persentase IoU antara 73,77% hingga 91,23%. Sedangkan nilai CPU time tercepat berada pada nilai 6,47 detik dan terlama yaitu 188,83 detik. Sementara rata-rata waktu proses segmentasi otomatis terbilang cepat karena hanya memakan waktu sekitar 39,09 detik. Tingkat *accuracy* dari metode ini sangat tinggi terlihat dari rata-rata perhitungan di atas yaitu sebesar 98,83%. Tingkat *precision* yang menunjukkan ketepatan hasil deteksi piksel sebesar 95,26%. Nilai rata-rata *sensitivity* yang diperoleh sebesar 86,58% hal ini menunjukkan


ukuran kemampuan mendeteksi piksel objek kanker cukup tinggi. Nilai *specificity* yang didapat memiliki rata-rata sebesar 99,63%. Sedangkan nilai *similarity* memiliki rata-rata sebesar 90,58% dan nilai rata-rata IoU yang didapat sebesar 82,87%. Nilai IoU ini digunakan untuk menentukan kesesuaian area segmentasi otomatis dengan *ground truth* manual, nilai tersebut dianggap cukup tinggi pada metode ACAC pada studi ini.




Gambar 16. Grafik hasil pengujian *accuracy*.




Gambar 17. Grafik hasil pengujian *precision*.




Gambar 18. Grafik hasil pengujian *sensitivity*.



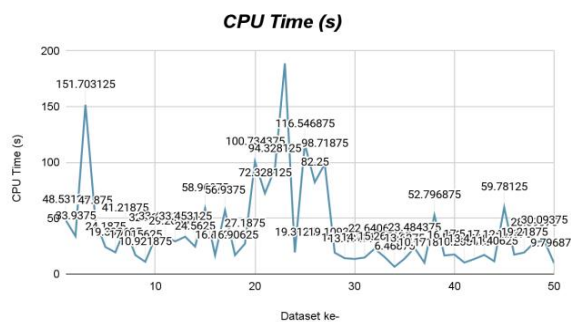
Gambar 19. Grafik hasil pengujian *specificity*.



Gambar 20. Grafik hasil pengujian *similarity*.



Gambar 21. Grafik hasil pengujian IoU.



Gambar 22. Grafik hasil pengamatan CPU Time.

V. KESIMPULAN

Studi ini berhasil mengembangkan metode segmentasi objek kanker otomatis pada citra USG untuk membantu radiolog dalam proses diagnosis yang efisien bernama *Automatic Combinatorial Active Contour* (ACAC). Metode ini diimplementasikan dalam sebuah program Python untuk melakukan segmentasi objek kanker tiroid dan payudara menghasilkan rata-rata waktu komputasi 39,09 detik. Angka tersebut terbilang cepat dalam mengakomodir efisiensi kinerja dokter untuk tidak melakukan segmentasi secara manual. Rata-rata tersebut dihasilkan menggunakan 50 dataset yang berasal dari Departemen Radiologi, RSUP Dr. Sardjito dan RSPAU dr. S. Hardjolukito Yogyakarta, Indonesia. Selain itu, tingkat *accuracy* dari metode ini sangat tinggi terlihat dari rata-rata perhitungan di atas yaitu sebesar 98,83%. Adapun untuk tingkat *precision* yang menunjukkan ketepatan hasil deteksi piksel sebesar 95,26%. Nilai rata-rata *sensitivity* yang diperoleh sebesar 86,58% hal ini menunjukkan ukuran kemampuan mendeteksi piksel objek kanker cukup tinggi. Nilai *specificity* yang didapat memiliki rata-rata sebesar 99,63%. Sedangkan nilai



similarity memiliki rata-rata sebesar 90,58% dan nilai rata-rata IoU yang didapat sebesar 82,87%. Nilai IoU ini digunakan untuk menentukan kesesuaian area segmentasi otomatis dengan *ground truth* manual. Nilai ini cukup tinggi pada metode ACAC terutama jika dibandingkan dengan performa model CV dan GAC sebagai pendahulunya. Dengan demikian, metode ACAC yang memanfaatkan metode *simplification* CV untuk melakukan *global segmentation* yang dilanjutkan dengan melakukan *local segmentation* menggunakan *improved-GAC* layak diimplementasikan pada sistem CAD sehingga diperoleh hasil diagnosis yang akurat dan rekomendasi klinis yang lebih objektif.

UCAPAN TERIMA KASIH

Studi ini merupakan bagian dari Penelitian Dasar yang didanai oleh DIPA Fakultas Teknik Universitas Negeri Semarang. Penulis mengucapkan terima kasih kepada dr. Lina Choridah, Sp. Rad. dan mahasiswa pembimbingnya di Departemen Radiologi, Fakultas Kedokteran, Universitas Gadjah Mada yang telah menyediakan dataset citra radiologi USG termasuk *ground truth* dan untuk semua diskusi berharga selama studi ini. Kami juga berterima kasih kepada rekan-rekan UNNES, khususnya rekan-rekan di Lab Big Data dan Lab AI di gedung Digital Center UNNES, yang telah memberikan ruang, wawasan, dan keahlian yang sangat membantu studi ini. Kami juga berterima kasih kepada para pengulas atas wawasannya.

DAFTAR PUSTAKA

- [1] A. Elangovan and T. Jeyaseelan, "Medical imaging modalities: A survey," *1st Int. Conf. Emerg. Trends Eng. Technol. Sci. ICETETS 2016 - Proc.*, pp. 2–5, 2016, doi: 10.1109/ICETETS.2016.7603066.
- [2] J. A. Noble and D. Boukerroui, "Ultrasound image segmentation: A survey," *IEEE Trans. Med. Imaging*, vol. 25, no. 8, pp. 987–1010, 2006, doi: 10.1109/TMI.2006.877092.
- [3] P. P. A. Smyth, "The thyroid and breast cancer: A significant association?," *Ann. Med.*, vol. 29, no. 3, pp. 189–191, 1997, doi: 10.3109/07853899708999335.
- [4] P. J. Hardefeldt, G. D. Eslick, and S. Edirimanne, "Benign thyroid disease is associated with breast cancer: A meta-analysis," *Breast Cancer Res. Treat.*, vol. 133, no. 3, pp. 1169–1177, 2012, doi: 10.1007/s10549-012-2019-3.
- [5] A. Angelousi *et al.*, "Is there an association between thyroid function abnormalities and breast cancer?," *Arch. Endocrinol. Metab.*, vol. 61, no. 1, pp. 54–61, 2017, doi: 10.1590/2359-3997000000191.
- [6] A. Rodríguez-Cristerna, W. Gómez-Flores, and W. C. de Albuquerque Pereira, "A computer-aided diagnosis system for breast ultrasound based on weighted BI-RADS classes," *Comput. Methods Programs Biomed.*, vol. 153, pp. 33–40, 2017, doi: 10.1016/j.cmpb.2017.10.004.
- [7] T. L. Szabo, *Diagnostic Ultrasound Imaging: Inside Out*. Elsevier, 2014. doi: 10.1016/C2011-0-07261-7.
- [8] R. Takahashi and Y. Kajikawa, "Computer-aided diagnosis: A survey with bibliometric analysis," *Int. J. Med. Inform.*, vol. 101, pp. 58–67, 2017, doi: 10.1016/j.ijmedinf.2017.02.004.
- [9] A. Nugroho, R. Hidayat, H. Adi Nugroho, and J. Debayle, "Cancerous object detection using morphological region-based active contour in ultrasound images," *J. Phys. Conf. Ser.*, vol. 1444, no. 1, 2020, doi: 10.1088/1742-6596/1444/1/012011.
- [10] W. Gómez-Flores and B. A. Ruiz-Ortega, "New fully automated method for segmentation of breast lesions on ultrasound based on texture analysis," *Ultrasound Med. Biol.*, vol. 42, no. 7, pp. 1637–1650, 2016, doi: 10.1016/j.ultrasmedbio.2016.02.016.
- [11] S. Wu, Q. Zhu, and Y. Xie, "Evaluation of various speckle reduction filters on medical ultrasound images," *Proc. Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. EMBS*, pp. 1148–1151, 2013, doi: 10.1109/EMBC.2013.6609709.
- [12] N. S. Narayan, P. Marziliano, and C. G. L. Hobbs, "Automatic removal of manually induced artefacts in ultrasound images of thyroid gland," *Proc. Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. EMBS*, pp. 3399–3402, 2013, doi: 10.1109/EMBC.2013.6610271.
- [13] B. Bhanu and S. Lee, *Genetic Learning for Adaptive Image Segmentation*. Springer US, 1994. [Online]. Available: https://books.google.co.id/books?id=2%5C_R9u%5C_xOZu4C
- [14] X. Wang, S. Li, J. Li, J. Wang, and M. Zhang, "A novel segmentation model with dual *level set* function based on Chan-vee and local binary fitting models," *2016 3rd Int. Conf. Syst. Informatics, ICSAI 2016*, no. Icsai, pp. 837–842, 2016, doi: 10.1109/ICSAI.2016.7811067.
- [15] D. Koundal, S. Gupta, and S. Singh, "Automated delineation of thyroid nodules in ultrasound images using spatial neutrosophic clustering and *level set*," *Appl. Soft Comput.*, vol. 40, pp. 86–97, Mar. 2016, doi: 10.1016/J.ASOC.2015.11.035.
- [16] H. D. Cheng, J. Shan, W. Ju, Y. Guo, and L. Zhang, "Automated breast cancer detection and classification using ultrasound images: A survey," *Pattern Recognit.*, vol. 43, no. 1, pp. 299–317, Jan. 2010, doi: 10.1016/J.PATCOG.2009.05.012.
- [17] S. Sridevi and M. Sundaresan, "Survey of image segmentation algorithms on ultrasound medical images," *Proc. 2013 Int. Conf. Pattern Recognition, Informatics Mob. Eng. PRIME 2013*, pp. 215–220, 2013, doi: 10.1109/ICPRIME.2013.6496475.
- [18] M. Xian, Y. Zhang, H. D. Cheng, F. Xu, B.



- Zhang, and J. Ding, "Automatic breast ultrasound image segmentation: A survey," *Comput. Vis. Pattern Recognit.*, pp. 10–71, Jul. 2017, doi: 10.1016/J.PATCOG.2018.02.012.
- [19] Q. Huang, Y. Luo, and Q. Zhang, "Breast ultrasound image segmentation: a survey," *Int. J. Comput. Assist. Radiol. Surg.*, vol. 12, no. 3, pp. 493–507, 2017, doi: 10.1007/s11548-016-1513-1.
- [20] K. M. Meiburger, U. R. Acharya, and F. Molinari, "Automated localization and segmentation techniques for B-mode ultrasound images: A review," *Comput. Biol. Med.*, vol. 92, pp. 210–235, 2018, doi: 10.1016/j.combiomed.2017.11.018.
- [21] A. Nugroho, R. Hidayat, and H. A. Nugroho, "Thyroid ultrasound image segmentation: A review," *Proc. - 2019 5th Int. Conf. Sci. Technol. ICST 2019*, 2019, doi: 10.1109/ICST47872.2019.9166443.
- [22] Y. Hu *et al.*, "Automatic tumor segmentation in breast ultrasound images using a dilated fully convolutional network combined with an active contour model," *Med. Phys.*, vol. 46, no. 1, pp. 215–228, 2019, doi: 10.1002/mp.13268.
- [23] A. Nugroho, R. Hidayat, H. A. Nugroho, and J. Debayle, "Ultrasound object detection using morphological region-based active contour: An application system," *Int. J. Innov. Learn.*, vol. 29, no. 4, pp. 412–430, 2021, doi: 10.1504/IJIL.2021.115497.
- [24] A. Nugroho, H. A. Nugroho, and L. Choridah, "Active contour bilateral filter for breast lesions segmentation on ultrasound images," in *2015 International Conference on Science in Information Technology (ICSITech)*, 2015, pp. 36–40. doi: 10.1109/ICSITech.2015.7407773.
- [25] D. Koundal, B. Sharma, and Y. Guo, "Intuitionistic based segmentation of thyroid nodules in ultrasound images," *Comput. Biol. Med.*, vol. 121, p. 103776, 2020, doi: 10.1016/j.combiomed.2020.103776.
- [26] J. jing Zong, T. shuang Qiu, W. dong Li, and D. mei Guo, "Automatic ultrasound image segmentation based on local entropy and active contour model," *Comput. Math. with Appl.*, vol. 78, no. 3, pp. 929–943, 2019, doi: 10.1016/j.camwa.2019.03.022.
- [27] A. Rodtook, K. Kirimasthong, W. Lohitvisate, and S. S. Makhanov, "Automatic initialization of active contours and *level set* method in ultrasound images of breast abnormalities," *Pattern Recognit.*, vol. 79, pp. 172–182, 2018, doi: 10.1016/j.patcog.2018.01.032.
- [28] 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," *J. Phys. Conf. Ser.*, vol. 1230, no. 1, p. 012002, 2019, doi: 10.1088/1742-6596/1230/1/012002.
- [29] T. F. Chan and L. A. Vese, "Active contours without edges," *IEEE Trans. Image Process.*, vol. 10, no. 2, pp. 266–277, 2001, doi: 10.1109/83.902291.
- [30] A. Nugroho, R. Hidayat, H. A. Nugroho, and J. Debayle, "Development of Active Contour Model For Radiological Ultrasound Image Segmentation," Universitas Gadjah Mada, 2021. [Online]. Available: <http://etd.repository.ugm.ac.id/penelitian/detail/204336>
- [31] A. Nugroho, R. Hidayat, H. A. Nugroho, and J. Debayle, "Combinatorial active contour bilateral filter for ultrasound image segmentation," *J. Med. Imaging*, vol. 7, no. 05, pp. 1–13, 2020, doi: 10.1117/1.jmi.7.5.057003.
- [32] V. Caselles, R. Kimmel, and G. Sapiro, "Geodesic Active Contours," *Int. J. Comput. Vis.*, vol. 22, no. 1, pp. 61–79, 1997, doi: 10.1023/A:1007979827043.
- [33] Z. Wang, K. Wang, F. Yang, S. Pan, and Y. Han, "Image segmentation of overlapping leaves based on Chan–Vese model and Sobel operator," *Inf. Process. Agric.*, vol. 5, no. 1, pp. 1–10, 2018, doi: 10.1016/j.inpa.2017.09.005.
- [34] A. Nugroho, R. Hidayat, H. Adi Nugroho, and J. Debayle, "Cancerous object detection using morphological region-based active contour in ultrasound images," *J. Phys. Conf. Ser.*, vol. 1444, no. 1, p. 12011, Jan. 2020, doi: 10.1088/1742-6596/1444/1/012011.
- [35] A. Nugroho, R. Hidayat, H. A. Nugroho, and J. Debayle, "Development of Active Contour Model For Radiological Ultrasound Image Segmentation," Universitas Gadjah Mada, 2021.
- [36] S. Ruuska, W. Hämäläinen, S. Kajava, M. Mughal, P. Matilainen, and J. Mononen, "Evaluation of the confusion matrix method in the validation of an automated system for measuring feeding behaviour of cattle," *Behav. Processes*, vol. 148, pp. 56–62, 2018.



©2021. This article is an open access article distributed under the terms and conditions of the [Creative Commons Attribution-ShareAlike 4.0 International License](https://creativecommons.org/licenses/by-sa/4.0/).