

# Peningkatan Akurasi Segmentasi Tulang *Femur* dan *Tibia* pada Citra Radiograf Menggunakan AASM

Rima Tri Wahyuningrum<sup>1,4</sup>, I Ketut Eddy Purnama<sup>2,3</sup>, Mauridhi Hery Purnomo<sup>2,3</sup>

**Abstract**—Osteoarthritis (OA) is a joint disease that affects a large part of the elderly population. One of the OA that is often experienced by patients is knee OA. To determine the development and classification of this disease, a process of segmenting the femur and tibia is needed quickly and accurately. Meanwhile, manual segmentation has several disadvantages including the longer time needed and the difference in the results of reading x-ray images between medical personnel with each other. Therefore, in this paper, an Adaptive Active Shape Model (AASM) is presented for femur and tibia segmentation on knee x-ray images. The purpose of this segmentation is to support the discovery and characterization of imaging biomarkers for the incidence, clinical evaluation, classification, and progression of knee osteoarthritis (OA). This new algorithm is adaptively capable of better segmenting the femur and tibia than the original ASM. In this experiment, 10 images were used as training data to get the mean shape model and 50 images were tested to find out performance of the method implemented. All images are taken randomly from Osteoarthritis Initiative (OAI) dataset. To determinate the accuracy of this segmentation method, calculations have been performed using Hausdorff Distance (HD) and Dice Similarity Coefficient (DSC). In addition, this study have also been compared with previous research (original ASM) and the same data is used. The best average result of the segmentation validation method from 50 test images in the AASM method using HD is 0.2016 for the right tibia femur bone using 43 landmarks and 0.9497 for the DSC. Based on these results, the average increase in accuracy of segmentation validation was 0.29 for HD and 0.33 for DSC. Thus, this method is quite reliable and clinically valuable for monitoring the progression of knee osteoarthritis.

**Intisari**— Osteoarthritis (OA) merupakan penyakit sendi yang memengaruhi sebagian besar populasi orang tua. Salah satu OA

yang sering dialami pasien adalah OA lutut. Untuk mengetahui perkembangan dan klasifikasi penyakit ini, diperlukan proses segmentasi tulang *femur* dan *tibia* secara cepat dan akurat. Sementara itu, segmentasi manual memiliki beberapa kelemahan, di antaranya waktu yang dibutuhkan lebih lama dan perbedaan hasil pembacaan citra radiograf (*x-ray*) antar tenaga medis satu dengan lainnya. Oleh karena itu, pada makalah ini sebuah *Adaptive Active Shape Model* (AASM) disajikan untuk segmentasi tulang *femur* dan *tibia* pada citra radiograf lutut. Tujuan dari segmentasi ini adalah mendukung penemuan dan karakterisasi *biomarker* pencitraan dari kejadian, evaluasi klinis, klasifikasi serta perkembangan OA lutut. Algoritme baru ini secara adaptif mampu melakukan segmentasi tulang *femur* dan *tibia* lebih baik daripada ASM asli. Dalam uji coba ini, sepuluh citra digunakan sebagai citra pelatihan untuk mendapatkan model bentuk rata-rata dan 50 citra diuji untuk mengetahui kinerja metode yang diterapkan. Semua citra tersebut diambil secara acak dari basis data *Osteoarthritis Initiative* (OAI). Untuk menentukan akurasi dari metode segmentasi ini, telah dilakukan perhitungan dengan menggunakan *Hausdorff Distance* (HD) dan *Dice Similarity Coefficient* (DSC). Selain itu, metode ini juga telah dibandingkan dengan penelitian sebelumnya (ASM asli) dan menggunakan data yang sama. Rata-rata terbaik hasil validasi metode segmentasi dari 50 citra uji pada metode AASM menggunakan HD adalah 0,2016 untuk tulang *femur tibia* kanan menggunakan 43 titik (*landmarks*) dan 0,9497 untuk DSC. Hasil tersebut menunjukkan rata-rata peningkatan akurasi validasi segmentasi sebesar 0,29 untuk HD dan 0,33 untuk DSC. Dengan demikian, metode ini cukup andal dan secara klinis bermanfaat untuk memantau perkembangan OA lutut.

**Kata Kunci**— osteoarthritis lutut, segmentasi, *Active Shape Model*, *Hausdorff Distance*, *Dice Similarity Coefficient*.

## I. PENDAHULUAN

Selama ini, masyarakat pada umumnya menganggap penyakit osteoarthritis (OA) merupakan penyakit sepele karena tidak menyebabkan kematian. Padahal jika tidak segera ditangani, penyakit ini dapat menyebabkan anggota tubuh tidak berfungsi normal bahkan kecacatan seumur hidup. Sekitar 18% penderita OA mengalami kesulitan dan keterbatasan dalam beraktivitas, kehilangan fungsi kapasitas kerja, dan penurunan kualitas hidup [1]. Data *World Health Organization* (WHO) tahun 2017 menunjukkan bahwa prevalensi penyakit OA meningkat dari tahun ke tahun. Prediksi global di seluruh dunia mencapai 18% wanita dan 9,6% pria berusia di atas 60 tahun memiliki indikasi OA [2]. Selain itu, data IRA tahun 2014 menunjukkan prevalensi penyakit ini di Indonesia mencapai 23,6%–31,3% dengan 50% di antaranya pada usia 65 tahun [3]. OA dapat terjadi di berbagai sendi seperti lutut, jari kaki, jari tangan, panggul, bahkan tulang belakang. Di antara OA yang paling umum adalah OA lutut. Prevalensi penyakit ini cukup

<sup>1</sup>Mahasiswa, Departemen Teknik Elektro, Fakultas Teknologi Elektro, Institut Teknologi Sepuluh Nopember, Jln. Teknik Mesin, Gedung B, C, dan AJ, Kampus ITS, Sukolilo, Surabaya 60111, Jawa Timur, Indonesia (telp: 031-5947302, fax : 031-5931237, e-mail: rima15@mhs.ee.its.ac.id).

<sup>2</sup>Dosen, Departemen Teknik Elektro, Fakultas Teknologi Elektro, Institut Teknologi Sepuluh Nopember, Jln. Teknik Mesin, Gedung B, C, dan AJ, Kampus ITS, Sukolilo, Surabaya 60111, Jawa Timur, Indonesia (telp: 031-5947302, fax : 031-5931237, e-mail: ketut@ee.its.ac.id, hery@ee.its.ac.id).

<sup>3</sup>Dosen, Departemen Teknik Komputer, Fakultas Teknologi Elektro, Institut Teknologi Sepuluh Nopember, Jln. Teknik Mesin, Gedung B dan C, Kampus ITS, Sukolilo, Surabaya 60111, Jawa Timur, Indonesia (telp: 031-5922936, e-mail: ketut@ee.its.ac.id, hery@ee.its.ac.id).

<sup>4</sup>Dosen, Program Studi Teknik Informatika, Fakultas Teknik, Universitas Trunojoyo Madura, Jln Raya Telang, Kamal, Bangkalan, Madura, Jawa Timur (telp: 031-3011146, fax: 031-3011506, email: rimatriwahyuningrum@trunojoyo.ac.id, rimatriwahyuningrum@gmail.com).

tinggi, yaitu mencapai 15,5% pada pria dan 12,7% pada wanita dengan usia antara 40–60 tahun [3].

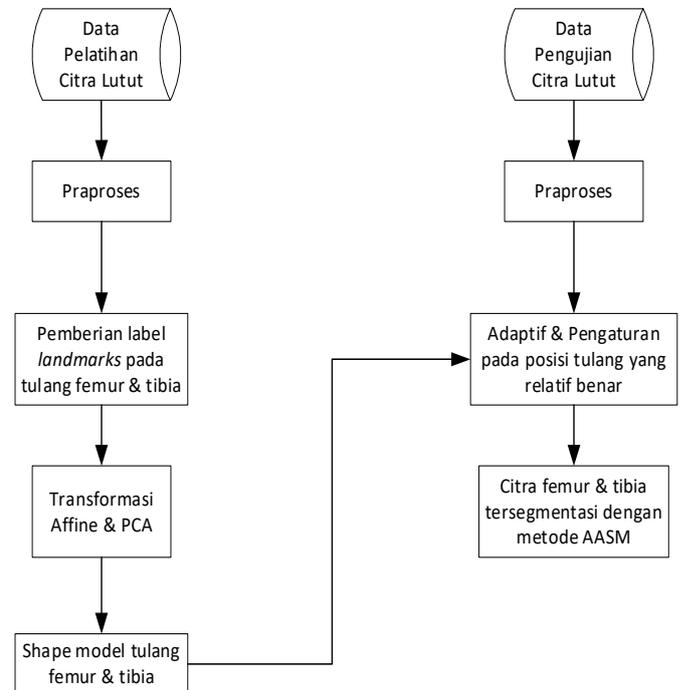
Secara umum, para ahli dan peneliti medis menggunakan informasi dari citra yang diperoleh dengan berbagai modalitas untuk mengetahui lebih detail tentang penyakit ini. Modalitas yang digunakan adalah radiografi (*x-ray*), *Magnetic Resonance Imaging* (MRI), *Computed Tomography* (CT), ultrasonografi, dan *Positron Emission Tomography* (PET) [4], [5]. Di antara modalitas tersebut, radiografi tetap dianggap sebagai *gold standard* untuk menilai tingkat keparahan penyakit OA lutut. Modalitas ini dipilih karena tidak invasif atau invasif minimal, murah, tepat, dan cepat [4]–[8]. Oleh karena itu, pada makalah ini digunakan citra radiograf lutut yang berasal dari basis data *Osteoarthritis Initiative* (OAI) [9].

Para peneliti telah melakukan beberapa riset terkait prediksi risiko dan deteksi perkembangan OA [6], [7], [10], [11]. Selain itu, beberapa peneliti juga terus mengembangkan penelitian untuk mengukur perubahan fitur tulang, penentuan usia tulang (secara otomatis), ataupun pengukuran kepadatan tulang. Penelitian-penelitian tersebut membutuhkan segmentasi yang akurat dan rekonstruksi tulang pada citra 2D maupun 3D [12]–[15]. Sementara ini, analisis hasil pemeriksaan citra medis secara manual memiliki beberapa kelemahan, yaitu membutuhkan waktu yang lama, rawan terhadap kesalahan pembacaan, serta sering terjadi variabilitas antara *intra-observer* dan *inter-observer* yang besar. Oleh karena itu, penelitian tentang segmentasi tulang dari citra radiograf menjadi subjek perhatian yang tajam. Diperlukan adanya metode segmentasi dengan bantuan komputer yang cepat dan andal serta menghasilkan akurasi (hasil pemeriksaan) yang akurat dan konsisten pada berbagai macam citra radiograf khususnya. Beberapa kelompok penelitian berfokus pada pengembangan metode komputasi untuk segmentasi yang akurat, baik sebagai metode semiotomatis maupun otomatis penuh [12]–[16]. Di lain hal, segmentasi juga diperlukan untuk membuat analisis kuantitatif berbagai modalitas untuk identifikasi penyakit seperti kanker serviks, tumor hati, *smear* serviks, dan masih banyak lagi lainnya [17]–[19].

Selama ini, masalah khas radiografi adalah kurangnya kontras antar objek yang tumpang tindih (*overlapping*), sehingga menyebabkan ambiguitas pada lokasi sebenarnya dari batas-batas objek citra. Metode segmentasi tingkat rendah hanya menggunakan kriteria intensitas lokal, seperti *thresholding*, *region growing*, atau deteksi tepi, sehingga tidak cukup untuk penggambaran objek yang akurat. Sementara itu, model kontur *deformable* dengan jumlah derajat kebebasan yang besar, seperti *active contours* (*snakes*) dan banyak model *deformable* lainnya, hanya mampu menangkap kompleksitas serta variabilitas antarindividu dari bentuk anatomi objek pada citra medis. Model ini memiliki kerugian, yaitu bebas mengambil hampir sembarang bentuk (secara halus) tanpa dibatasi pada bentuk keseluruhan yang merupakan karakteristik jenis objek tertentu [14].

Untuk mengatasi hal tersebut, telah dilakukan beberapa penelitian segmentasi tulang menggunakan *Active Shape Model* (ASM). Implementasi metode ini menunjukkan kinerja yang cukup memuaskan [12]–[16]. Namun, penelitian

sebelumnya terkait segmentasi tulang *femur-tibia* menunjukkan hasil akurasi yang kurang optimal [20]. Oleh karena itu, makalah ini mempresentasikan pengembangan metode ASM yaitu *Adaptive Shape Model* (AASM) pada tulang *femur-tibia*, sehingga tujuan makalah ini adalah peningkatan akurasi hasil segmentasi dengan metode yang dikembangkan untuk membantu dokter ortopedi dalam memprediksi risiko terjadinya OA lutut.



Gbr. 1 Diagram blok dari metode AASM yang diterapkan untuk segmentasi tulang *femur* dan *tibia*.

## II. DATA DAN METODE

### A. Data

Semua *dataset* eksperimental yang digunakan pada makalah ini berasal dari *dataset* OAI citra radiograf [9]. Enam puluh citra dipilih secara acak. Selanjutnya, citra-citra ini dibagi menjadi dua *dataset*, yaitu sepuluh citra sebagai data pelatihan dan 50 citra sebagai data pengujian, masing-masing untuk lutut kanan dan kiri. Data pelatihan digunakan sebagai pembelajaran pola untuk mendapatkan model bentuk (*shape model*) tulang *femur* dan *tibia*, sedangkan data pengujian digunakan untuk menganalisis kinerja metode ASM dan AASM.

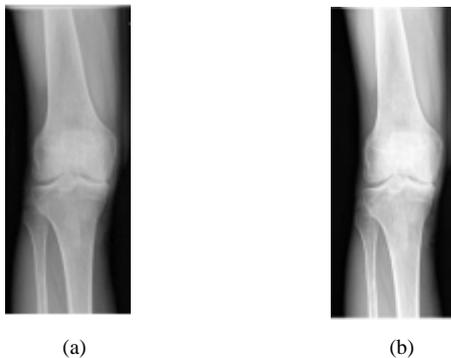
### B. Metode

Secara keseluruhan, diagram blok penelitian terdiri atas dua bagian, yaitu pelatihan dan pengujian, seperti yang ditunjukkan pada Gbr. 1. Pada kedua bagian dari diagram blok tersebut dilakukan praproses dengan cara menormalisasi dimensi citra dan melakukan penajaman kualitas citra dengan metode *Contrast Limited Adaptive Histogram Equalization* (CLAHE). Proses selanjutnya adalah melakukan pengolahan data pelatihan hingga diperoleh *mean shape/shape model* dari hasil pemberian titik-titik (*landmarks*) pada kontur tulang *femur*

maupun *tibia*, proses transformasi *affine*, dan *Principal Component Analysis* (PCA). Kemudian, *shape model* yang diperoleh pada *dataset* pelatihan diujikan pada semua citra di data pengujian menggunakan metode AASM, sehingga diperoleh citra tersegmentasi tulang *femur* dan *tibia*. Berikut ini penjelasan lebih lanjut tentang metodologi penelitian yang digunakan.

1) *Praproses*: Tahap awal dalam penelitian ini yaitu praproses dari citra radiograf lutut dengan cara melakukan normalisasi dimensi citra dan penajaman kualitas citra menggunakan metode CLAHE. Tujuan normalisasi dimensi citra adalah untuk menghilangkan piksel-piksel di luar citra lutut sehingga mempercepat proses pengolahan citra selanjutnya. Semua citra radiograf lutut dinormalisasi menjadi dimensi standar, yaitu  $4.262 \times 3.484$ . Sedangkan tujuan penggunaan metode CLAHE adalah untuk menajamkan kualitas citra. Metode ini merupakan pengembangan dari metode *Histogram Equalization* (HE). HE baik digunakan bila histogram dari citra terbatas pada wilayah tertentu. Jika variasi intensitas dari citra itu besar (piksel terang dan gelap) dan mencakup wilayah yang luas, maka hasil HE tidak optimal. Untuk mengatasi hal tersebut, maka digunakan metode CLAHE.

Dalam hal ini, citra dibagi menjadi blok-blok kecil. Kemudian masing-masing blok ini disamakan/diekualisasi dengan histogram seperti biasa. Jadi, histogram akan terbatas pada wilayah kecil. Jika ada derau (*noise*), maka derau akan diperkuat. Untuk menghindarinya, maka pembatasan kontras (*contrast limited*) diterapkan. Jika ada histogram *bin* di atas batas kontras yang ditentukan, maka piksel-piksel itu terpotong dan didistribusikan secara seragam ke *bin* lain sebelum menerapkan HE. Setelah itu, untuk menghapus objek di batas blok, maka interpolasi bilinear diterapkan. Contoh hasil praproses dengan metode CLAHE ditunjukkan pada Gbr. 2.

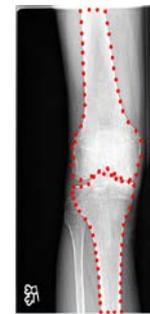


Gbr. 2 Contoh citra hasil praproses, (a) citra asli, (b) citra setelah praproses dengan metode CLAHE.

2) *Pengembangan Metode Active Shape Model (ASM)*: ASM merupakan metode analisis citra statistik yang membagi perbedaan bentuk menjadi mode variasi kontinu. Pada makalah ini, pengembangan metode ASM digunakan untuk menggambarkan variasi bentuk pada tulang *femur* dan *tibia*. Metode ini dipilih karena telah banyak penelitian yang membuktikan keandalannya [12]–[16], [20]–[22]. Selain itu, metode ASM telah berhasil dimodifikasi dan diperbaiki sehingga menghasilkan segmentasi yang semakin baik [21]–[25].

Pada makalah ini disajikan metode segmentasi ASM yang adaptif dan secara akurat mengekstrak kontur tulang pada citra radiograf lutut. Adaptif yang dimaksud adalah algoritme ini dapat mengekstrak informasi global dari citra radiograf lutut sehingga yang diambil hanya titik tepi yang paling menonjol. Kemudian dilakukan pencarian kontur aktif pada citra radiograf lutut untuk mendapatkan titik kontur kandidat dengan gradien intensitas tertinggi. AASM membatasi kontur dalam bentuk yang layak, sehingga mengarah pada hasil segmentasi yang akurat. Metode ini menangkap variasi tampilan yang besar, sehingga memecahkan keterbatasan ASM dengan menggunakan *Active Appearance Model* (AAM). Kelemahan penggunaan AAM pada ASM adalah memiliki mode rata-rata tunggal yang tidak cukup untuk menangkap variasi ruang penampilan dengan satu distribusi Gaussian. Batasan lainnya adalah citra radiograf tulang yang mengalami degenerasi menciptakan *outliers*, sehingga dapat menyebabkan segmentasi yang salah, seperti yang dilakukan pada penelitian sebelumnya [20].

Pada penelitian ini, *dataset* citra pelatihan meliputi satu set kontur tulang *femur* dan *tibia* (kanan maupun kiri) yang selaras satu sama lain. Proses AASM seperti yang ditunjukkan pada Gbr. 1 dimulai dengan menandai *landmarks* pada batas tulang *femur* dan *tibia* oleh operator (*user*) pada data pelatihan. Untuk mengetahui kinerja metode ini, digunakan perbandingan skenario uji coba yaitu jumlah titik 25 dan 43. Gbr. 3 menunjukkan skenario uji coba menggunakan 43 titik, baik pada tulang *femur* maupun *tibia*, dengan peletakan titik tepat di tepi tulang. Proses berikutnya adalah menginterpolasi titik-titik ini dengan *cubic spline* untuk mendapatkan kontur. Titik-titik yang sesuai (berkorespondensi) di antara kontur-kontur tersebut diidentifikasi dari titik kontur yang diinterpolasi.



Gbr. 3 Penandaan 43 *landmarks* (titik merah) pada citra pelatihan, masing-masing untuk tulang *femur* dan *tibia* kanan.

Langkah selanjutnya yaitu melakukan penyesuaian *centroid* yang kaku menggunakan algoritme iteratif standar *vertex-to-vertex* pada titik terdekat. Kemudian, dilakukan transformasi *affine* untuk menyesuaikan kontur citra pelatihan menjadi kontur baru dengan menggunakan 12 derajat kebebasan (rotasi, translasi, skala, dan pemotongan). Titik-titik baru pada kontur baru dibuat dengan karakteristik spasial lokal yang sama untuk *template* konturnya. Dengan demikian, satu set citra pelatihan yang dihasilkan terdiri atas kontur pelatihan  $N$  yang dilambangkan sebagai  $S$ , mengacu pada (1).

$$S = \{C^\alpha \mid \alpha \in \{1, \dots, N\}\} \quad (1)$$

dengan setiap kontur  $C^\alpha C S$  memiliki satu set titik *landmark*  $X^\alpha C C^\alpha$ , dengan  $X^\alpha = \{C_n^\alpha | n \in \{1, \dots, M\}\}$  dan  $C_n^\alpha = (x_n^\alpha, y_n^\alpha)$  merupakan koordinat dari titik *landmark* pada  $C^\alpha$ . Setelah bentuk (*shapes*) dari data pelatihan diselaraskan, maka rata-rata bentuk (*mean shape*) dihitung menggunakan (2).

$$\bar{X} = \{\bar{C}_n | n \in \{1, \dots, N\}\} \quad (2)$$

dengan  $\bar{C}_n = (\bar{x}_n, \bar{y}_n)$ ;  $\bar{x}_n = (\frac{1}{K}) \sum_a x_m^a$ ;  $\bar{y}_n = (\frac{1}{K}) \sum_a y_m^a$ ; dan  $K$  adalah jumlah titik-titik pada setiap kontur.

Proses berikutnya adalah menerapkan metode PCA pada *dataset* citra pelatihan, sehingga bentuk tulang lutut yang valid ( $x$ ) dapat direpresentasikan sebagai (3).

$$x = \bar{x} + \varphi_s b \quad (3)$$

dengan  $\bar{x}$  adalah rata-rata model (*mean model*) dan  $\varphi_s = (\varphi_1, \varphi_2, \dots, \varphi_n)$  adalah matriks dari *eigenvector* yang bersesuaian dengan  $m$  terbesar *eigenvalue* ( $\lambda_i$ ) berdasarkan matriks *covariance* (4).

$$P = [\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(x_i - \bar{x})^T] \quad (4)$$

Nilai  $m$  dipilih menjadi bilangan terkecil yang mewakili lebih dari 98% dari varians citra pelatihan, yaitu  $\sum_{i=1}^m \frac{\lambda_i}{\sum_{i=1}^n \lambda_i} > 0,98$ , sedangkan  $n$  adalah jumlah total *eigenvector*. *Eigenvector* ( $\varphi_s$ ) mewakili basis ortogonal dari mode deformasi linear yang menggambarkan bahwa titik-titik cenderung bergerak bersama karena bentuknya bervariasi. Sementara itu, *eigenvalue* ( $\lambda_i$ ) yang sesuai merupakan varians dari masing-masing mode deformasi linear. Parameter model bentuk (*shape model*),  $b$ , dihitung oleh  $b = \varphi_s^T (x - \bar{x})$ . Ketika penyesuaian (*fitting*) model menjadi satu set titik-titik, nilai-nilai  $b$  dibatasi berada dalam jangkauan (*range*)  $\pm 3\sqrt{\lambda_i}$  [25].

Proses selanjutnya yakni melakukan pengujian pada 50 citra uji berdasarkan *shape model* tulang *femur-tibia* yang telah terbentuk pada proses pelatihan. Inisialisasi pada setiap citra uji dilakukan dengan cara meletakkan *shape model* tepat di tengah antara tulang *femur-tibia*. Selanjutnya, secara adaptif *shape model* melakukan penyesuaian model dengan citra uji. Terakhir, terbentuk hasil segmentasi tulang *femur-tibia*, baik pada lutut kanan maupun kiri.

3) *Validasi Kinerja Metode AASM*: Untuk menguji kinerja metode AASM, hasil segmentasi citra uji metode ini dibandingkan dengan *ground truth* yang diperoleh dari segmentasi manual oleh pakar (*user*). Penelitian ini menggunakan dua metode validasi, yaitu *Hausdorff Distance* (HD) [26] dan *Dice Similarity Coefficient* (DSC) [27] sebagai evaluasi kuantitatif berkaitan dengan kemampuan menemukan batas objek (segmentasi) yang benar. HD adalah ukuran ketidaksamaan yang umum digunakan untuk membandingkan titik-titik manual dan titik hasil segmentasi citra [26], seperti ditunjukkan pada (5).

$$\hat{H}(E, F) = \max_{x \in E} \{\min_{y \in F} \{\|x, y\|\}\} \quad (5)$$

dengan  $\hat{H}$  (HD berarah) adalah jarak maksimum antara setiap titik  $x \in E$  dan tetangga terdekatnya  $y \in F$ . Dalam hal ini, titik-

titik hasil segmentasi manual adalah  $E$  dan titik-titik hasil segmentasi metode AASM adalah  $F$ . Sebagai catatan,  $\hat{H}(E, F) \neq \hat{H}(F, E)$  sehingga berlaku sifat asimetris. Oleh karena itu, perlu diberlakukan sifat simetris, yang artinya jarak maksimum dari kedua kumpulan titik diarahkan pada kedua arah, seperti ditunjukkan pada (6).

$$H(E, F) = \max\{\hat{H}(E, F), \hat{H}(F, E)\} \cdot \quad (6)$$

Sedangkan DSC merupakan indeks tumpang tindih (*overlap*) spasial dan validasi *reproductivity* metrik. Nilai DSC berkisar dari 0 (menunjukkan tidak ada tumpang tindih spasial antara dua set hasil segmentasi biner) hingga 1 (menunjukkan tumpang tindih lengkap) [27]. Dalam hal ini, DSC mengukur tumpang tindih spasial antara dua segmentasi, yaitu wilayah target  $A$  dan  $B$ , dengan  $A$  adalah hasil segmentasi manual,  $B$  adalah hasil segmentasi metode AASM dan  $\cap$  adalah interseksi/irisan sehingga DSC didefinisikan sebagai (7).

$$DSC = 2(A \cap B)/(A + B). \quad (7)$$

Berdasarkan penjelasan kedua metode validasi tersebut, jika nilai HD mendekati 0 berarti menunjukkan perbandingan metode yang semakin baik. Sebaliknya, jika nilai DSC mendekati 1 berarti menunjukkan *overlap* yang mendekati sempurna.

### III. HASIL EKSPERIMEN

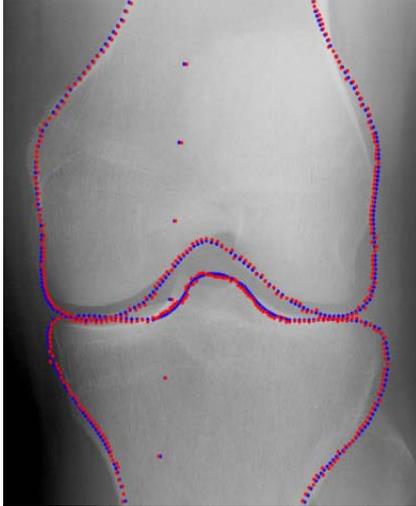
Makalah ini menggunakan citra dari *dataset* umum OAI, yaitu *dataset* klinis dari *anteroposterior* yang dipilih secara acak pada radiograf lutut untuk subjek yang menderita OA [9]. Citra tersebut telah dikumpulkan dari berbagai pusat radiografi, sehingga menghasilkan perbedaan intensitas yang besar karena penggunaan radiografi dan peralatan rekaman yang berbeda. Oleh karena itu, perlu dilakukan praproses sebelum dilakukan segmentasi dengan metode AASM. Seperti dijelaskan pada subbagian sebelumnya, pada makalah ini digunakan praproses normalisasi ukuran dimensi citra dan CLAHE untuk penajaman kualitas citra yang digunakan, baik sebagai *dataset* pelatihan maupun pengujian.

Selain itu, keberadaan tulang dan jaringan lunak yang berdekatan dapat menyebabkan salah segmentasi. Hal itu terjadi ketika *shape model* memiliki intensitas tepi pada citra lebih kuat daripada target tulang. Oleh karena itu, algoritme segmentasi yang andal menjadi penting untuk segmentasi yang akurat pada berbagai variasi citra radiograf.

Uji coba ini dirancang untuk memvalidasi algoritme segmentasi yang dipresentasikan. *Statistical shape model* dihitung berdasarkan pelatihan kontur pada *dataset* citra lutut, kemudian dari kontur tulang *femur-tibia* yang terbentuk dilakukan analisis hasil. Kontur tulang diekstraksi baik pada lutut kanan maupun kiri. Masing-masing bagian lutut terdiri atas sepuluh citra radiograf yang digunakan sebagai *dataset* pelatihan, dengan setiap lutut terdiri atas tulang *femur* dan *tibia*. Selanjutnya *shape model* yang terbentuk diujikan pada 50 citra radiograf lutut sebagai *dataset* pengujian (lutut kanan maupun kiri).

Gbr. 4 merupakan contoh hasil uji coba pada *dataset* pengujian. Titik-titik biru (hasil interpolasi dari *landmarks*)

merupakan *shape model* yang dihasilkan dari *dataset* pelatihan, sedangkan titik-titik merah merupakan AASM yang mendekati ketepatan segmentasi tulang *femur* dan *tibia*. Seperti dijelaskan pada subbagian sebelumnya, titik merah menyesuaikan titik biru (*shape model*) yang disebut sebagai proses *fitting*. Hasil kualitatif dari proses ini adalah segmentasi citra uji yang mengikuti bentuk *shape model* tulang *femur* dan *tibia*, seperti ditunjukkan pada Gbr. 5.



Gbr. 4 Contoh dari uji coba metode AASM yang diterapkan.

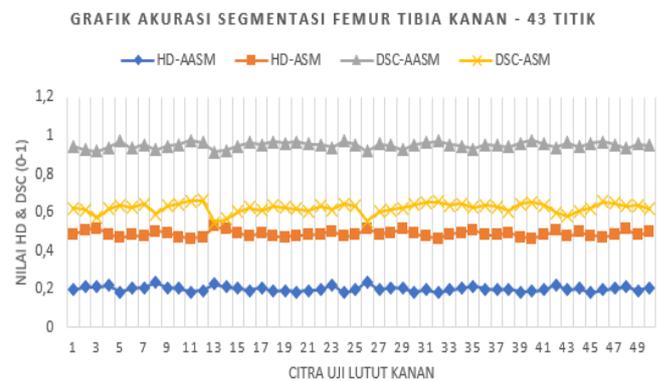


Gbr. 5 Contoh kualitas hasil segmentasi dari dua citra uji.

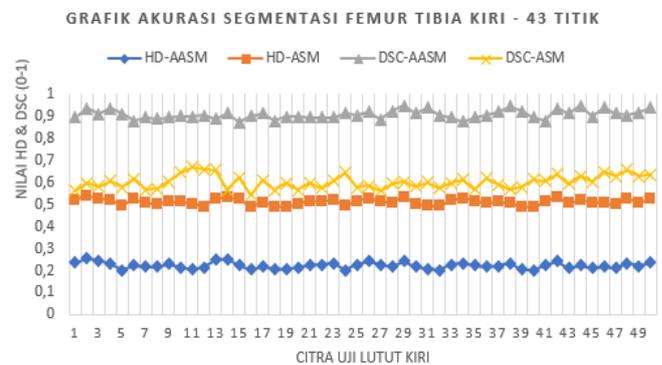
Selanjutnya, untuk menguji kinerja metode AASM, makalah ini membandingkan hasil segmentasi citra uji metode AASM yang diusulkan (titik-titik interpolasi bagian dalam) dengan *ground truth* (titik-titik interpolasi bagian luar) yang diperoleh dari manual segmentasi oleh pakar (*user*), seperti ditunjukkan pada Gbr. 6. Pada gambar tersebut dilakukan proses *zoom* untuk melihat lebih detail perbedaan kedua hasil segmentasi tersebut. Sebagaimana yang telah diuraikan pada subbagian sebelumnya, metode validasi yang digunakan adalah HD dan DSC. Selain itu, makalah ini juga membandingkan metode yang diuji coba dengan metode ASM asli [20], seperti yang ditunjukkan pada Gbr. 7 sampai Gbr. 10.



Gbr. 6 Contoh perbandingan hasil segmentasi metode AASM dan *ground truth*.



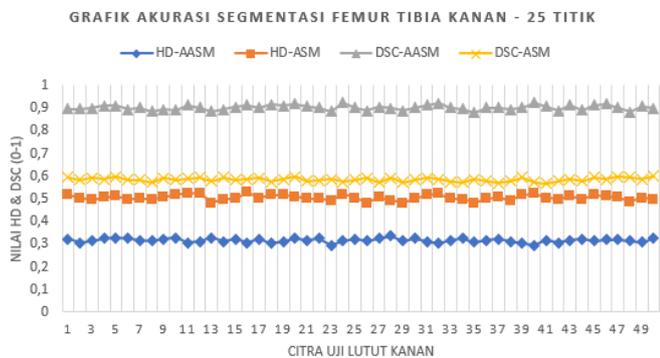
Gbr. 7 Grafik perbandingan akurasi segmentasi *femur* dan *tibia* kanan dengan menggunakan 43 titik (*landmarks*).



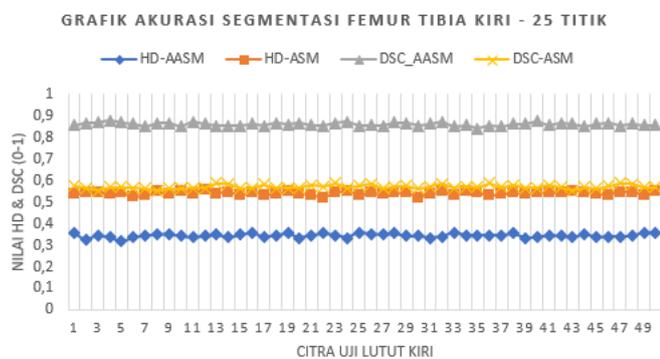
Gbr. 8 Grafik perbandingan akurasi segmentasi *femur* dan *tibia* kiri dengan menggunakan 43 titik (*landmarks*).

Gbr. 7 dan Gbr. 8 merupakan grafik perbandingan dari pengukuran akurasi (validasi) hasil segmentasi *femur-tibia* kanan maupun kiri menggunakan 43 titik (*landmarks*), sedangkan Gbr. 9 dan Gbr. 10 merupakan grafik perbandingan yang sama tetapi menggunakan 25 titik (*landmarks*). *Landmarks* tersebut diterapkan pada sepuluh citra pelatihan untuk membentuk *mean shape model*. Kemudian *mean shape model* yang terbentuk digunakan pada 50 citra uji untuk mendapatkan hasil segmentasi *femur-tibia* kanan maupun kiri.

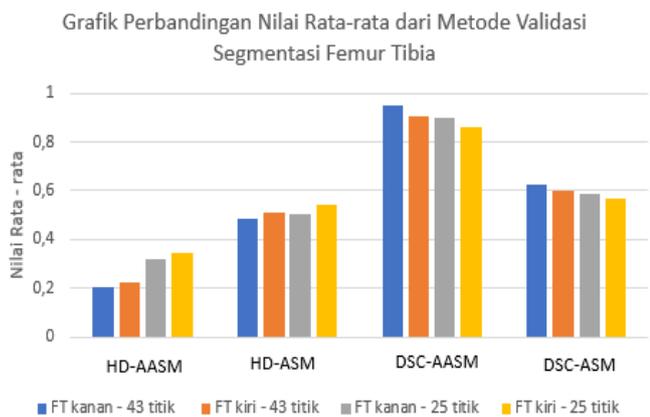
Berdasarkan keempat grafik perbandingan tersebut, titik-titik biru menunjukkan nilai HD dari metode AASM dengan *ground truth*; titik-titik jingga merupakan nilai HD dari metode ASM dengan *ground truth*; titik-titik kuning merupakan nilai DSC dari metode ASM dengan *ground truth*; dan titik-titik abu-abu merupakan nilai DSC dari metode AASM dengan *ground truth*.



Gbr. 9 Grafik perbandingan akurasi segmentasi femur dan tibia kanan dengan menggunakan 25 titik (*landmarks*).



Gbr. 10 Grafik perbandingan akurasi segmentasi femur dan tibia kiri dengan menggunakan 43 titik (*landmarks*).



Keterangan: FT = femur-tibia

Gbr. 11 Grafik perbandingan nilai rata-rata dari metode validasi segmentasi femur dan tibia.

Sebagaimana yang telah disampaikan pada subbagian sebelumnya, HD dan DSC memiliki rentang nilai antara 0 dan 1. HD bernilai bagus jika hasil pengukuran perbandingan segmentasi AASM atau ASM dengan *ground truth* mendekati

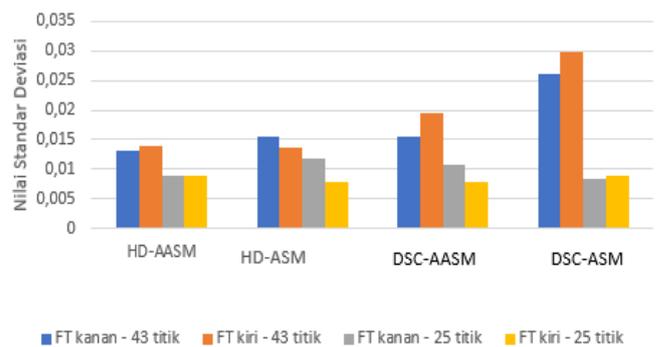
0, sedangkan untuk DSC berlaku sebaliknya. Hasil rata-rata dan standar deviasi dari nilai HD dan DSC dari Gbr. 7 sampai Gbr. 10 ditunjukkan pada Gbr. 11 dan Gbr. 12 serta Tabel I dan Tabel II. Pada Gbr. 11 dan Gbr. 12, diagram batang biru menunjukkan nilai rata-rata dan standar deviasi pada hasil segmentasi femur-tibia kanan menggunakan 43 *landmarks*; diagram batang jingga menunjukkan nilai rata-rata dan standar deviasi pada hasil segmentasi femur-tibia kiri menggunakan 43 *landmarks*; diagram batang abu-abu menunjukkan nilai rata-rata dan standar deviasi pada hasil segmentasi femur tibia kanan menggunakan 25 *landmarks*; dan diagram batang kuning menunjukkan nilai rata-rata dan standar deviasi pada hasil segmentasi femur tibia kiri menggunakan 25 *landmarks*.

TABEL I  
NILAI RATA-RATA METODE VALIDASI HASIL SEGMENTASI

Nilai rata-rata	HD - AASM	HD - ASM	DSC - AASM	DSC - ASM
Kanan - 43	0,2016	0,4879	0,9497	0,6230
Kiri - 43	0,2225	0,5111	0,9074	0,6015
Kanan - 25	0,3164	0,5049	0,9021	0,5847
Kiri - 25	0,3443	0,5404	0,8609	0,5702

Gbr. 11 dan Tabel I menunjukkan bahwa nilai rata-rata metode segmentasi AASM lebih baik daripada ASM. Untuk metode validasi HD pada AASM, nilai rata-rata terbaik (mendekati 0) yaitu 0,2016, pada hasil segmentasi femur-tibia kanan dengan menggunakan 43 *landmarks*. Sedangkan untuk metode validasi DSC, nilai rata-rata terbaik (mendekati 1) yaitu 0,9497, terjadi pada hasil segmentasi yang sama. Hal ini disebabkan pada AASM kontur yang dihasilkan pada citra uji secara adaptif mampu mengikuti *mean shape model* yang dihasilkan pada *dataset* citra pelatihan. Metode ini mampu menghindari titik-titik yang tidak sesuai ketika terjadi kesalahan segmentasi akibat adanya nilai kontras citra yang rendah dan tulang lain di sekitar tulang femur dan tibia.

Grafik Perbandingan Nilai Standar Deviasi dari Metode Validasi Segmentasi Femur Tibia



Keterangan: FT = femur-tibia

Gbr. 12 Grafik perbandingan nilai standar deviasi dari metode validasi segmentasi femur dan tibia.

Selain itu, berdasarkan Gbr. 11 dan Tabel I, tampak bahwa semakin banyak jumlah titik (*landmarks*) yang digunakan, maka hasil segmentasi yang diperoleh semakin bagus. Hal tersebut terjadi karena *mean shape model* yang dihasilkan lebih mendekati bentuk segmentasi yang diharapkan.

TABEL II  
NILAI STANDAR DEVIASI METODE VALIDASI HASIL SEGMENTASI

Nilai standar deviasi	HD - AASM	HD - ASM	DSC - AASM	DSC - ASM
Kanan - 43	0,01324	0,01564	0,01560	0,02618
Kiri - 43	0,01387	0,01370	0,01949	0,02976
Kanan - 25	0,00881	0,01172	0,01084	0,00832
Kiri - 25	0,00900	0,00784	0,00777	0,00900

Sementara itu, berdasarkan Gbr. 12 dan Tabel II, tampak bahwa nilai standar deviasi mendekati 0. Hal ini menandakan bahwa semua nilai hasil segmentasi, baik metode AASM maupun ASM, adalah hampir sama. Selain itu, nilai rata-rata menunjukkan bahwa hasil segmentasi *femur-tibia* kanan lebih bagus daripada kiri.

#### IV. KESIMPULAN

Berdasarkan eksperimen yang telah dilakukan, penggunaan metode AASM untuk segmentasi tulang *femur* dan *tibia* menunjukkan hasil yang lebih baik daripada metode ASM. Metode ini secara adaptif mampu menghasilkan segmentasi yang memiliki nilai rata-rata mendekati 0 untuk uji validasi metode menggunakan HD dan mendekati 1 untuk uji validasi menggunakan DSC. Metode evaluasi kuantitatif ini membandingkan segmentasi dari metode yang diusulkan (AASM maupun ASM) dengan segmentasi manual yang diperoleh dari pakar (*user*). Selain itu, berdasarkan hasil tersebut, jumlah titik (*landmarks*) memengaruhi hasil segmentasi *femur-tibia*. Semakin banyak jumlah titik yang digunakan, maka hasil segmentasi juga semakin bagus. Dengan demikian, metode AASM ini cukup andal dan baik digunakan untuk segmentasi tulang *femur* dan *tibia* sehingga secara klinis mampu mengetahui perkembangan OA pasien.

#### UCAPAN TERIMA KASIH

Ucapan terima kasih disampaikan kepada basis data OAI yang telah menyediakan data untuk uji coba metode pada penelitian ini dan Kemenristek Dikti yang telah memberikan BPPDN dalam penyelesaian program doktor.

#### REFERENSI

- [1] A.W. Sudoyo, B. Setiyohadi, I. Alwi, M. Simadibrata, dan S. Setiati, "Buku Ajar Ilmu Penyakit Dalam Jilid II Edisi V", Jakarta, Indonesia: Interna Publishing, 2009.
- [2] (2018) "Chronic rheumatic conditions" [Online], <https://www.who.int/chp/topics/rheumatic/en/>, tanggal akses: 22 Mei 2018.
- [3] *Rekomendasi IRA untuk Diagnosis dan Penatalaksanaan Osteoarthritis*, Diagnosis dan Penatalaksanaan Osteoarthritis, 2014.
- [4] D. Hayashi, F.W. Roemer, dan A. Guermazi, "Review: Imaging for osteoarthritis," *Annals of Physical and Rehabilitation Medicine*, Vol. 59, hal. 161-169, 2016.
- [5] W.M. Oo, J.M. Linklater, dan D.J. Hunter, "Imaging in Knee Osteoarthritis", *Therapy*, Vol. 7, No. 6, hal. 635-647, 2010.
- [6] L. Shamir, S.M. Ling, W.W. Scott, A. Bos, N. Orlov, T.J. Macura, D.M. Eckley, L. Ferrucci, dan I.G. Goldberg, "Knee X-Ray Image Analysis Method for Automated Detection of Osteoarthritis," *IEEE Transaction on Biomedical Engineering*, Vol. 56, No. 2, hal. 407-415, 2009.
- [7] G.W. Stachowiak, M. Wolski, T. Woloszynski, dan P. Podsiadlo, "Detection and Prediction of Osteoarthritis in Knee and Hand Joints Based on the X-Ray Image Analysis," *Biosurface and Biotribology*, Vol. 2, No. 4, hal. 162-172, Dec 2016.
- [8] N. Hafezi-Nejad, A. Guermazi, S. Demehri, dan F.W. Roemer, "New Imaging Modalities to Predict and Evaluate Osteoarthritis Progression", *Best Practice & Research Clinical Rheumatology*, Vol. 31, No. 5, hal. 688-704, Okt. 2017.
- [9] (2016) Laman Osteoarthritis Initiative [Online], <http://www.oai.ucsf.edu/>, tanggal akses: 15-Jan-2016.
- [10] R.T. Wahyuningrum, L. Anifah, I.K.E. Purnama, dan M.H. Purnomo, "A Novel Hybrid of S2DPCA and SVM for Knee Osteoarthritis Classification," *2016 IEEE International Conference on Computational Intelligence and Virtual Environments for Measuring Systems and Applications (CIVEMSA 2016)*, 2016, hal. 57-61.
- [11] R. Riad, R. Jennane, A. Brahim, T. Janvier, H. Toumi, dan E. Lespessailles, "Texture Analysis Using Complex Wavelet Decomposition for Knee Osteoarthritis Detection: Data from the Osteoarthritis Initiative," *Computers and Electrical Engineering*, Vol. 68, hal. 181-191, 2018.
- [12] J.A. Lynch, N. Parimi, R.K. Chaganti, M.C. Nevitt, dan N.E. Lane, "The Association of Proximal Femoral Shape and Incident Radiographic Hip OA in Elderly Women," *Osteoarthritis and Cartilage*, Vol. 17, No. 10, hal. 1313-1318, 2009.
- [13] C. Chen, W. Xie, J. Franke, P.A. Grutzner, L.-P. Nolte, dan G. Zheng, "Automatic X-Ray Landmark Detection and Shape Segmentation Via Data-Driven Joint Estimation of Image Displacement," *Medical Image Analysis*, Vol. 18, No. 3, hal. 487-499, 2014.
- [14] B.L. Wise, L. Kritikos, J.A. Lynch, F. Liu, N. Parimi, K.L. Tileston, dan M.C. Nevitt, "Proximal Femur Shape Differs between Subjects with Lateral and Medial Knee Osteoarthritis and Controls: The Osteoarthritis Initiative," *Osteoarthritis and Cartilage*, Vol.22, No. 12, hal. 2067-2073, 2014.
- [15] B.L. Wise, F. Liu, L. Kritikos, J.A. Lynch, N. Parimi, Y. Zhang, dan N.E. Lane, "The Association of Distal Femur and Proximal Tibia Shape with Sex: The Osteoarthritis Initiative," *Seminars in Arthritis and Rheumatism*, Vol. 46, No. 1, hal. 20-26, 2016.
- [16] A. Gandhamal, S. Talbar, S. Gajre, R. Razak, A.F.M. Hani, dan D. Kumar, "Fully Automated Subchondral Bone Segmentation from Knee MR Images: Data from the Osteoarthritis Initiative," *Computers in Biology and Medicine*, Vol. 88, hal. 110-125, 2017.
- [17] D.A. Dharmawan, "Deteksi Kanker Serviks Otomatis Berbasis Jaringan Saraf Tiruan LVQ dan DCT", *Jurnal Nasional Teknik Elektro dan Teknologi Informasi (JNTETI)*, Vol. 6, No. 1, hal. 107-114, 2017.
- [18] N.P. Husain dan C. Faticah, "Segmentasi Citra Sel Tunggal Smear Serviks Menggunakan Radiating Component Normalized Generalized GVFS," *Jurnal Nasional Teknik Elektro dan Teknologi Informasi (JNTETI)*, Vol. 6, No. 1, hal. 107-114, 2017.
- [19] N. Syakrani, Y. Widhiyasa, dan A.A. Efendi, "Deteksi Tumor Hati dengan Graph Cut dan Taksiran Volume Tumornya," *Jurnal Nasional Teknik Elektro dan Teknologi Informasi (JNTETI)*, Vol. 7, No. 1, hal. 35-43, 2018.
- [20] K.I. Pangestuti dan I.K.E. Purnama, "Pengukuran Sudut Tibia dan Femur pada Citra X-Ray Menggunakan Active Shape Model (ASM)", *Prosiding Seminar Nasional Pendidikan Teknik Informatika (SENAPATI 2015)*, 2015, hal.134-139.
- [21] M. Esfandiarkhani dan A.H. Foruzan, "A Generalized Active Shape Model for Segmentation of Liver in Low-Contrast CT Volumes", *Computers in Biology and Medicine*, Vol. 82, hal. 59-70, 2017.
- [22] X. Chen, J.K. Udupa, A. Alavi, dan D.A. Torigian, "GC-ASM: Synergistic Integration of Graph-Cut and Active Shape Model Strategies for Medical Image Segmentation," *Computer Vision and Image Understanding*, Vol. 117, No. 5, hal. 513-524, 2013.
- [23] C. Lindner, S. Thiagarajah, J.M. Wilkinson, The arcOGEN Consortium, G.A. Wallis dan T.F. Cootes, "Fully Automatic Segmentation of the Proximal Femur Using Random Forest Regression Voting," *IEEE Trans. Med. Imaging*, Vol. 32, No. 8, hal.1462-1472, 2013.
- [24] J. Mu, X. Liu, S. Luan, P.H. Heintz, G.W. Mlady, dan D.Z. Chen, "Segmentation of Knee Joints in X-Ray Images Using Decomposition-

- Based Sweeping and Graph Search,” *Proc. SPIE 7962, Medical Imaging 2011: Image Processing*, 2011, hal. 1-8.
- [25] T.F. Cootes dan C.J. Taylor, “Statistical Models of Appearance for Computer Vision,” University of Manchester, Manchester, United Kingdom, Technical Report, hal. 1-125, 2000.
- [26] A.A Taha dan A. Hanbury, “An Efficient Algorithm for Calculating the Exact Hausdorff Distance,” *IEEE Trans Pattern Anal Mach Intell*, Vol. 37, No. 11, hal. 2153–2163, 2015.
- [27] K.H. Zou, S.K. Warfield, A. Bharatha, C.M. C. Tempany, M.R. Kaus, S. J. Haker, W.M. Wells, F.A. Jolesz, dan R. Kikinis, “Statistical Validation of Image Segmentation Quality Based on a Spatial Overlap Index—Scientific Reports,” *Acad. Radiol.*, Vol. 11, No. 2, hal. 178–189, 2004.