

PENGEMBANGKAN MODEL EKSTRAKSI REGION OF INTEREST SECARA OTOMATIS PADA CITRA CT-SCAN

¹Sri Widodo*, ²Mohammad Faizuddin Bin MD Noor, ³Zalizah Awang Long

¹Universitas Duta Bangsa Surakarta, sri_widodo.udb.ac.id

²Universiti Kuala Lumpur, Malaysia, mfaizuddin@unikl.edu.my

³Universiti Kuala Lumpur, Malaysia, zalizah@unikl.edu.my

*Penulis Korespondensi

ABSTRAK

Kanker paru adalah pertumbuhan sel kanker yang tidak terkontrol dalam jaringan paru. Akhir-akhir ini banyak peneliti yang telah menerapkan deep learning, khususnya Convolution Neural Network (CNN) untuk klasifikasi kanker paru. Proses deteksi kanker paru didahului dengan tahapan ekstraksi Region Of Interest (ROI). Ekstraksi ROI dalam deteksi kanker paru terdiri dari dua kegiatan, yaitu segmentasi bidang paru dan operasi segmentasi kandidat kanker paru. Sebagian besar penelitian tentang deteksi kanker menggunakan CNN, proses ekstraksi ROI dilakukan secara manual dengan melakukan cropping. Proses ini sulit dilakukan, khususnya dalam mensegmentasi bidang paru, yaitu memisahkan area paru dengan jaringan di sekitarnya. Jika kelainan tersebut besar dan terletak pada batas tepi paru, menyebabkan batas tepi paru tidak jelas, sehingga jika dilakukan segmentasi, citra yang dicurigai sebagai kanker tidak akan masuk dalam citra paru (bagian paru yang terdapat kanker akan hilang). Sehingga segmentasi bidang paru dianggap gagal. Penelitian yang diusulkan bertujuan untuk mengembangkan model ekstraksi Region Of Interest (ROI) secara otomatis menggunakan metode Active Shape Model dan Mathematical Morphology pada citra CT-Scan. Penelitian yang diusulkan terdiri dari dua tahapan, yaitu, segmentasi bidang paru menggunakan metode Active Shape Model (ASM) dan segmentasi kandidat paru menggunakan metode Mathematical Morphology. Hasil segmentasi paru dengan metode Active Shape Model mempunyai akurasi 97,2.8%, sensitivitas 96%, dan spesifisitas 97.4%. Sedangkan hasil segmentasi kandidat kanker paru dengan metode morfologi mempunyai akurasi 99,4%, sensitivitas 96,2%, dan spesifisitas 99.7%.

Kata Kunci : ASM, CNN, Morfologi.

ABSTRACT

Lung cancer is the uncontrolled growth of cancer cells in lung tissue. Recently, many researchers have applied deep learning, especially the Convolution Neural Network (CNN) for lung cancer classification. The process of detecting lung cancer is preceded by the Region Of Interest (ROI) extraction stage. ROI extraction in lung cancer detection consists of two activities, namely lung field segmentation and lung cancer candidate segmentation surgery. Most of the research on cancer detection uses CNN, the ROI extraction process is done manually by cropping. This process is difficult, especially in segmenting the lung fields, that is, separating the lung area from the surrounding tissue. If the abnormality is large and located on the periphery of the lung, it causes the periphery of the lung to be unclear, so that if segmentation is performed, the image suspected of being cancer will not be included in the lung image (the part of the lung where there is cancer will disappear). So that lung field segmentation is considered failed. The proposed research aims to develop an automatic Region Of Interest (ROI) extraction model using the Active Shape Model and Mathematical Morphology methods on CT-Scan images. The proposed research consists of two stages, namely, lung field segmentation using the Active Shape Model (ASM) method and lung candidate segmentation using the Mathematical Morphology method. The results of lung segmentation using the Active Shape Model method had an accuracy of 97.2.8%, a sensitivity of 96% and a specificity of 97.4%. Meanwhile, the results of lung cancer candidate segmentation using the morphology method had an accuracy of 99.4%, a sensitivity of 96.2%, and a specificity of 99.7%.

Keyword : ASM, CNN, Morfology.

PENDAHULUAN

Secara umum, kanker paru-paru mengacu pada segala bentuk kanker di paru-paru, termasuk kanker yang berkembang di dalam paru-paru dan kanker yang berkembang di luar paru-paru (metastasis tumor di paru-paru) (American Lung Association, 2018) (Niknam et al., 2011), sedangkan lesi kecil, bulat atau berbentuk telur di paru-paru disebut nodul (kanker jinak). Nodul paru atau kanker jinak biasanya memiliki diameter 3-4 cm (tidak lebih dari 6 cm) dan selalu dikelilingi oleh jaringan paru yang sehat (Halmos et al., 2019)(Thompson et al., 2019)(Kustanto, Widodo & Tomo, 2015)(Zhou et al., 2016)(Abbas, 2017)(Tian et al., 2012)(Song et al., 2017)(Tran et al., 2019). Kanker paru-paru biasanya dapat diidentifikasi secara visual oleh dokter menggunakan gambar CT scan. Prosedur diagnosis melibatkan melihat kumpulan data gambar CT

scan 2-D dan mengevaluasi setiap scan secara individual. Hasil cetak dibaca dengan memproyeksikan gambar CT dan X-ray ke lampu baca. Cara ini tentu saja kurang efektif. Diagnosis kanker paru, baik jinak maupun ganas, bisa berbeda-beda tergantung ahli paru (Makaju et al., 2018; Chen et al., 2017). Bisa juga tergantung dari jenis, bentuk, ukuran, dan lokasi kanker di organ paru-paru (Colakoglu et al., 2019). Deteksi dini kanker paru-paru pada gambar CT scan sangat penting.

Akhir-akhir ini banyak peneliti yang telah menerapkan deep learning, khususnya Convolution Neural Network (CNN) untuk mendeteksi kanker paru. Penelitian pertama adalah penelitian dari Atsushi (Atsushi Teramoto, 2019). Penelitian ini menggunakan deep convolutional neural network (CNN) untuk secara otomatis mengklasifikasikan sel paru ganas dari gambar mikroskopis. Gambar diambil menggunakan kamera digital yang dipasang pada lensa optik dengan fokus 40mm. Ekstraksi ROI dilakukan dengan cara cropping secara manual. Memanfaatkan augmentasi data, gambar dibuat dengan memutar, membalik, memfilter, dan menyesuaikan warna. Berdasarkan model VGG-16 yang disesuaikan dengan Afine, kategorisasi DCNN telah selesai. Area gambar kanker ganas tersegmentasi menggunakan tambalan, dan akurasi klasifikasi dinilai menggunakan validasi silang tiga kali lipat. Menurut temuan klasifikasi, sensitivitas dan spesifisitas masing-masing adalah 89,3 dan 83,3%.

Penelitian selanjutnya adalah penelitian dari Yuya Onishi (Yuya Onishi, 2019). Deep convolutional neural network (DCNN) digunakan dalam penelitian ini untuk secara otomatis mengklasifikasikan nodul paru pada gambar CT. Ekstraksi ROI dilakukan dengan cara cropping secara manual. Studi ini menyelidiki apakah akurasi klasifikasi ditingkatkan dengan menggunakan generative adversarial network (GANs) untuk menghasilkan gambar dalam jumlah besar. Teknik yang disarankan digunakan untuk menganalisis CT dari 60 kasus dengan diagnosis patologis yang diverifikasi dengan biopsi. Dengan menggunakan prosedur pretraining dan fine-tuning ini, 66,7% nodul jinak dapat dibedakan dari 93,9% nodul ganas. Temuan ini menunjukkan bahwa pendekatan yang disarankan meningkatkan keberhasilan klasifikasi relatif terhadap pelatihan hanya dengan gambar asli sekitar 20%.


Teknik pembelajaran mendalam baru diajukan oleh Giang Son Tran (Giang Son Tran, 2019) untuk meningkatkan akurasi klasifikasi deteksi nodul paru. Tujuan dari penelitian ini adalah untuk mengkategorikan potensi lesi paru pada CT scan sebagai nodul atau nonnodul. Ekstraksi ROI dilakukan dengan cara cropping secara manual. Untuk ekstraksi fitur otomatis dan teknik klasifikasi menggunakan 15-layer. Setelah pelatihan, fungsi Focal loss digunakan untuk meningkatkan akurasi kategorisasi. Teknik deep learning menggunakan focal loss menghasilkan klasifikasi berkualitas tinggi dengan akurasi, sensitivitas, dan spesifisitas sebesar 97,3%, 96,0%, dan 97,2%.

Teknik Convolution Neural Network untuk mengidentifikasi kanker paru-paru menggunakan data CT scan asli dari salah satu dari tiga penelitian deteksi kanker CNN, dan ekstraksi ROI dilakukan secara manual melalui cropping. Operasi ROI sangat menentukan dalam proses deteksi kanker paru. Ekstraksi ROI dalam deteksi kanker paru terdiri dari dua kegiatan, yaitu segmentasi bidang paru dan operasi segmentasi kandidat kanker paru. Operasi ROI digunakan untuk mendapatkan objek yang akan dideteksi, dalam hal ini adalah citra yang dicurigai sebagai kanker paru (kandidat kanker). Proses ini sulit dilakukan, khususnya dalam mensegmentasi bidang paru, yaitu memisahkan area paru dengan jaringan di sekitarnya. Jika kelainan tersebut besar dan terletak pada batas tepi paru, menyebabkan batas tepi paru tidak jelas, sehingga jika dilakukan segmentasi, citra yang dicurigai sebagai kanker tidak akan masuk dalam citra paru (bagian paru yang terdapat kanker akan hilang). Sehingga segmentasi bidang paru dianggap gagal. Penelitian yang diusulkan bertujuan untuk mengembangkan model ekstraksi Region Of Interest (ROI) secara otomatis menggunakan metode Active Shape Model dan Mathematical Morphology pada citra CT-Scan. Penelitian yang diusulkan terdiri dari dua tahapan, yaitu, segmentasi bidang paru menggunakan metode Active Shape Model dan segmentasi

kandidat paru menggunakan metode Mathematical Morphology. Penelitian ini diharapkan dapat meningkatkan tingkat akurasi dalam mendiagnosis kanker paru pada citra CT-Scan.

METODE

Ekstraksi Region Of Interest (ROI) dilakukan dengan segmentasi citra CT untuk mendapatkan citra yang diduga sebagai kanker paru. Pemodelan ekstraksi ROI yang diusulkan ditunjukkan pada Gambar 1.



Gambar 1. Pemodelan yang Diusulkan Untuk Ekstraksi ROI

Proses ekstraksi ROI terdiri dari dua tahap. Secara rinci dapat dijelaskan sebagai berikut.

A. Segmentasi Bidang Paru-paru

Langkah pertama dalam ekstraksi Region of Interest (ROI) adalah segmentasi citra paru-paru. Metode yang diusulkan untuk segmentasi paru-paru adalah Active Shape Model (ASM). Active Shape Model (ASM) adalah model statistik yang dimulai pada tahun 1990-an oleh Tim Cootes (Tim Cootes, 1995). Tahapan pertama pada ASM adalah membentuk model menggunakan posisi penunjuk (*landmark*) dari citra pada data training. Tahapan-tahapan dalam segmentasi paru menggunakan ASM dapat dijelaskan sebagai berikut.

1. Analisis Procrustes

Analisis Procrustes [20] adalah suatu model analisis bentuk statistik menggunakan analisis koleksi dari bentuk-bentuk. Pada kasus ini, bentuk-bentuk disamakan dengan merubah komponen translasi, rotasi dan skala. Uraian singkat tahapan untuk memasang bentuk $X = (x_1, y_1, x_2, y_2, \dots, x_n, y_n)$ dan $Z = (z_1, w_1, z_2, w_2, \dots, z_n, w_n)$ dapat dijelaskan sebagai berikut:

a. Translasi

Menghitung nilai tengah dari massa untuk setiap bentuk:

$$\bar{x} = \frac{x_1 + \dots + x_n}{n}, \bar{y} = \frac{y_1 + \dots + y_n}{n}, \bar{z} = \frac{z_1 + \dots + z_n}{n}, \bar{w} = \frac{w_1 + \dots + w_n}{n} \tag{1}$$

Translasi setiap bentuk ke pusat dari massa:

$$(x', y') \mapsto (x - \bar{x}, y - \bar{y}), (z', w') \mapsto (z - \bar{z}, w - \bar{w}) \tag{2}$$

b. Scaling

Menghitung skala untuk masing-masing bentuk menggunakan L_2 -norm:

$$ScaleX = \sqrt{x_1'^2 + y_1'^2 + x_2'^2 + y_2'^2 + \dots + x_n'^2 + y_n'^2}$$

$$ScaleZ = \sqrt{z_1'^2 + w_1'^2 + z_2'^2 + w_2'^2 + \dots + z_n'^2 + w_n'^2}$$

(3)

$$X' = \frac{X'}{ScaleX}, Z' = \frac{Z'}{ScaleZ} \tag{4}$$

c. Rotasi

Membangun \underline{X} dan \underline{Z} seperti berikut:

$$\underline{X} = \begin{pmatrix} x_1' & x_2' & \dots & x_n' \\ y_1' & y_2' & \dots & y_n' \end{pmatrix}, \underline{Z} = \begin{pmatrix} z_1' & z_2' & \dots & z_n' \\ w_1' & w_2' & \dots & w_n' \end{pmatrix} \tag{5}$$

Menghitung *Singular Value Decomposition* (SVD) untuk $\underline{Z}^T * \underline{X}$ dan menemukan U, S, V.

Rotasi matrik (R) untuk mencocokkan \underline{Z} dengan \underline{X} :

$$R = V * U^T = \begin{pmatrix} \cos(\theta) & -\sin(\theta) \\ \sin(\theta) & \cos(\theta) \end{pmatrix} \tag{6}$$

Menghitung $Z_{rotasi} = R * \underline{Z}$. (7)

2. Penjajaran Bentuk (Shape Alignment)

Bentuk dari objek pada data training berbeda pada proses skala, rotasi dan translasi. Agar supaya tercipta model bentuk yang stabil, perbedaan harus dihilangkan. Pendekatan standar adalah menjajarkan semua bentuk pada mean shape dan melanjutkan prosedur ini sampai mean shape tidak merubah pada dua iterasi berikutnya.

3. Principle Component Analysis (PCA)

PCA adalah transformasi orthogonal linear yang mentransmisikan dataset kepada sistem koordinat baru sebagai varian terbesar pertama pada data satu dimensi. *Principle Component* adalah eigenvectors dari matrik kovarian. Jika \sum_s adalah matrik kovarian dari bentuk training, kami mendapatkan $\sum_s * P_s = P_s * \Lambda_s$ yang mana Λ_s menunjukkan suatu matrik diagonal dari eigenvalues:

$$\Lambda_s = \begin{pmatrix} \lambda_{s,1} & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & \lambda_{s,2N_i} \end{pmatrix} \tag{8}$$

4. Pencarian Citra

Pada tahapan ini, suatu estimasi inisial dari bentuk diaplikasikan secara manual pada citra yang tak terlihat. Bentuk inisial harus diletakkan pada tepi objek dari citra yang tidak kelihatan dan direspon pada waktu yang bersamaan. Selanjutnya ASM menggunakan profil tepi dan matrik kovarian dari mean derivative normal untuk menemukan pergerakan terbaik.

5. Estimasi Bentuk Inisialisai

Pertama-tama *user* harus memilih bentuk sebagai bentuk inisialisasi. Jika X_i adalah bentuk inisialisasi, ini dapat dipertimbangkan sebagai translasi, rotasi dan penskalaan dari bentuk referensi (X_{ref}):

$$X_i = M(s_i, \theta_i)[X_{ref}] + t_i \tag{9}$$

Dimana

$$M(s, \theta) = s \times \begin{pmatrix} \cos(\theta) & -\sin(\theta) \\ \sin(\theta) & \cos(\theta) \end{pmatrix} \tag{10}$$

$$t_i = [t_{x,i}, t_{y,i}, t_{x,i}, t_{y,i}, \dots, t_{x,i}, t_{y,i}]^T \tag{11}$$

dan X_{ref} adalah suatu kombinasi dari \bar{X} dan parameter model:

$$X_{ref} = \bar{X} + P.b_{ref} \tag{12}$$

Kemudian rumus terakhir adalah :

$$X_i = M(s_i, \theta_i)[\bar{X} + P.b_{ref}] + t_i \tag{13}$$

(biasanya $b_{ref} = 0$, sehingga $X_{ref} = \bar{X}$)

6. Merubah Pose dan Parameter Model

Inisialisasi bentuk dilakukan dengan merubah pose dan parameter model. Perubahan dapat dimodelkan sebagai $X_i \rightarrow X_i + d_x$, dengan arti X_i adalah menggantikan $X_i + d_x$, dimana

$$d_{X_i} = (d_{X_i,pose}, d_{X_i,model}), d_{X_i,pose} = (1 + d_s, d_\theta, d_t) \text{ dan } d_{X_i,model} = P^T . d_b \tag{14}$$

a. Menghitung Perubahan Parameter Pose.

Pengaruh dari modifikasi parameter pose pada X_i adalah:

$$X_i = M(s_i, \theta_i)[X_{ref}] + t_i \xrightarrow{(1+d_s, d_\theta, d_t)} X_i + d_{X_i,pose} \text{ or} \tag{15}$$

$$X_{temp} \Leftarrow M(s_i(1 + d_s), \theta_i + d_\theta)[X_{ref}] + t_i + d_{t_i} \tag{16}$$

b. Menghitung Perubahan Parameter Model

Setelah perubahan parameter pose, penyesuaian terakhir dapat dilakukan menggunakan modifikasi parameter model. Modifikasi hanya merubah X_{ref} pada persamaan terakhir:

$$X_{ref} \rightarrow X_{ref} + d_{X_i,model} \text{ atau } X_{ref} \rightarrow X_{ref} + P^T . d_b \tag{17}$$

Selanjutnya modifikasi X_i oleh d_{X_i} final adalah:

$$X_i + d_{X_i} = M(s_i(1 + d_s), \theta_i + d_\theta)[X_{ref} + d_{X_i,model}] + t_i + d_{t_i} \tag{18}$$

Dengan kombinasi persamaan ini dengan $X_i = M(s_i, \theta_i)[X_{ref}] + t_i$ dan pertimbangan

$M^{-1}(s, \theta) = M(s^{-1}, -\theta)$ kami mempunyai :

$$d_{X_i,model} = P^T . d_b = M((s_i(1 + d_s))^{-1}, -\theta_i - d_\theta) [M(s_i, \theta_i)X_{ref} + d_{X_i} - d_{t_i}] - X_{ref} \tag{19}$$

c. Menghitung Pergerakan Tiap (Penunjuk) Landmark

Seperti diketahui, persamaan terakhir adalah independen dan tidak ada relasi antara persamaan tersebut dengan objek yang diinginkan pada citra yang tidak tampak. Supaya terjadi hubungan, profil tepi dari setiap *landmark* pada bentuk inisialisasi harus dihitung. Berikut ini adalah *flowchart* perhitungan pergerakan tiap *landmark*:

Untuk *landmark* ke j pada X_i :

1. Menemukan profil keabuan yang melintasi garis bagi.

$$S_j = [g_{j,0}, g_{j,1}, \dots, g_{j,ns-1}] \tag{20}$$

2. Menghitung profil derivative dari S_j

$$dS_j = [g_{j,1} - g_{j,0}, g_{j,2} - g_{j,1}, \dots, g_{j,ns-2} - g_{j,ns-1}] \tag{21}$$

3. Normalisasi Derivatif

$$Y_{sj} = \frac{dS_j}{\sum_{k=0}^{ns-2} |dS_{j,k}|} \tag{22}$$

4. $h(d)$ menunjukkan sub-internal dari Y_{sj} yang tepusat pada piksel ke d dari Y_{sj}

5. Menemukan d untuk meminimalisasi $f(d) = (h(d) - \bar{Y}_j)^T C_j^{-1} (h(d) - \bar{Y}_j)$ (23)

6. *d* menunjukkan jarak.

B. Segmentasi Kandidat Kanker Paru

Tahapan-tahapan dalam segmentasi kandidat kanker menggunakan matematika morfologi dapat dijelaskan sebagai berikut:

1. Pengurangan Citra Paru Dengan Citra Paru Negatif

Proses pengurangan dilakukan dengan tahapan sebagai berikut:

- a. Citra paru hasil segmentasi dengan ASM dilakukan proses komplemen, yang akan menghasilkan citra paru negatif. Komplemen pada citra biner, nilai nol menjadi satu dan sebaliknya. Komplemen dari intensitas atau citra RGB, didapatkan dari hasil pengurangan nilai piksel maksimum (255) dikurangi dengan nilai pada citra. Keluaran dari komplemen suatu citra adalah jika area citra gelap menjadi terang, dan sebaliknya.
- b. Pengurangan antara citra paru dengan citra paru negatif.
- c. Hasil pengurangan di atas akan dilakukan proses morfologi.

2. Deteksi Tepi

Deteksi tepi objek merupakan operasi yang mendeteksi perubahan tingkat keabuan yang signifikan dari suatu citra. Perubahan tingkat intensitas diukur oleh suatu gradien citra. Misalnya suatu citra $f(x,y)$ adalah fungsi dua dimensi, maka vektor gradien dari x dan y masing-masing adalah merupakan turunan pertama terhadap x dan y yang dapat dituliskan dalam bentuk persamaan (Mark, 2008).

$$G = \begin{bmatrix} G_x \\ G_y \end{bmatrix} = \begin{bmatrix} \frac{\partial f(x,y)}{\partial x} \\ \frac{\partial f(x,y)}{\partial y} \end{bmatrix} \tag{24}$$

Operator gradien menghitung perubahan intensitas tingkat keabuan dan arah perubahan yang terjadi. Perubahan tersebut dihitung melalui perbedaan nilai dari tetangga-tetangga piksel tersebut. Dalam citra dua dimensi, gradien didekati menggunakan persamaan 25.

$$G = \begin{bmatrix} G_x \\ G_y \end{bmatrix} = \begin{bmatrix} f(x+1,y) - f(x,y) \\ f(x,y+1) - f(x,y) \end{bmatrix} \tag{25}$$

Pada persamaan di atas dapat dituliskan dalam bentuk matrik

$$G_x = \begin{bmatrix} -1 & 1 \end{bmatrix} \tag{26}$$

Dan

$$G_y = \begin{bmatrix} 1 \\ -1 \end{bmatrix} \tag{27}$$

Sedangkan besaran dari gradien dapat dihitung menggunakan beberapa model persamaan, salah satunya ditunjukkan pada persamaan 28.

$$G[f(x,y)] = \sqrt{G_x^2 + G_y^2} \tag{28}$$

Deteksi tepi yang digunakan pada penelitian ini adalah: deteksi tepi dengan metode konvolusi prewit. Ukuran yang digunakan Prewit adalah 3x3 dengan elemen horisontal yang ditengah untuk G_x sama dengan 0 dan elemen vertikal yang di tengah untuk G_y juga sama dengan 0, seperti diperlihatkan pada persamaan 29 dan 30 di bawah ini.

$$G_x = \begin{bmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{bmatrix} \tag{29}$$

Dan

$$G_y = \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix} \tag{30}$$

3. Threshold

Thresholding merupakan proses pemisahan piksel-piksel berdasarkan derajat keabuan yang dimilikinya. Piksel yang memiliki derajat keabuan lebih kecil dari nilai batas yang ditentukan akan diberikan nilai 0, sementara piksel yang memiliki derajat keabuan yang lebih besar dari batas akan diubah menjadi bernilai 1.

4. Dilasi

Fungsi dilatasi adalah menambahkan piksel pada pinggirannya tiap objek biner yaitu daerah yang memiliki nilai 1. Dimana dilatasi menambahkan 8 piksel yang saling berhubungan pada sekeliling objek. Dan dilasi merupakan proses penggabungan titik-titik latar (0) menjadi bagian dari objek (1). Penggunaan dilasi adalah letakkan titik poros S pada titik A. Beri angka 1 untuk semua titik (x,y) yang terkena atau tertimpa oleh struktur S pada posisi tersebut. Persamaan dilasi ditunjukkan pada persamaan 9 di bawah ini:

$$D(A,S)=A+S \tag{31}$$

5. Mengisi Daerah Gambar

Untuk mengisi daerah gambar digunakan algoritma berdasarkan rekonstruksi morfologi. Yang dimaksud daerah gambar adalah daerah piksel gelap yang dikelilingi oleh piksel lebih terang. Setelah lokasi gambar ditentukan, operasi selanjutnya adalah mengisi lokasi (daerah gambar) dengan menggunakan 4 koneksi tetangga latar belakang untuk citra input 2-D dan 6-Koneksi tetangga latar belakang untuk 3-D input. Output dari proses ini adalah daerah yang dikelilingi oleh piksel yang berwarna terang akan mempunyai nilai satu.

6. Erosi

Fungsi erosi adalah menghilangkan 8 piksel dari objek biner yang berhubungan dengan pinggirannya dari objek. Erosi merupakan penghapusan titik objek (1) menjadi bagian dari latar (0). Penggunaan erosi adalah letakkan titik poros S pada titik A tersebut. Jika ada bagian dari S yang berada di luar A maka titik poros dihapus atau dijadikan latar. Erosi ditunjukkan dengan persamaan 32 di bawah ini.

$$E(A,S)=A \times S \tag{32}$$

7. Perkalian

Perkalian citra dilakukan untuk mendapatkan citra kandidat nodul final. Perkalian citra dapat dilakukan dengan mengalikan setiap piksel dengan nilai tertentu. Secara matematis dapat dimodelkan menggunakan persamaan 33 di bawah ini.

$$\forall f(x,y); Nf(x,y) = f(x,y) * Th \tag{33}$$

$$\forall Nf(x,y); \text{if } Nf(x,y) > 255 \text{ then } Nf(x,y) = 255 \tag{34}$$

Dengan

$$Th \geq 1$$

F(x,y) adalah citra asal, Nf(x,y) adalah citra hasil perkalian antara intensitas citra asal dengan nilai Th. Pada penelitian ini proses perkalian merupakan perkalian antara citra mask kandidat kanker hasil proses erosi, dengan citra hasil pengurangan komplemen.

HASIL DAN PEMBAHASAN

Eksperimen pertama adalah segmentasi citra CT scan paru pada irisan ke 29 dengan kelainan bentuk yang besar seperti yang terlihat pada Gambar 2 dan Gambar 3.






Figure 2. Proses Segmentasi Dengan ASM

Hasil segmentasi paru ditunjukkan pada gambar 3.




Gambar 3. (a) Kontur Paru-paru, (b). Gambar Paru-paru Final


Hasil segmentasi paru selengkapnya ditunjukkan pada Gambar 4,5 dan 6 di bawaah ini.



Gambar 4. Gambar CT Pasien Secara Berurutan




Gambar 5. Kontur Hasil Segmentasi dengan ASM



Gambar 6. Gambar Paru-paru.

Perbandingan hasil segmentasi dengan thresholding, active contour segmentation dan ASM, diperlihatkan pada Gambar 7. Pada metode thresholding dan Active Contour, jika kelainannya besar, maka kelainatersebut tidak termasuk dalam citra paru.



(d)
 Figure 7. Lung Segmentation Results In Great Shape abnormalities
 (a) . Manual segmentation Results By Groundtruth, (b). With Thresholding Segmentation, (c).
 The results of the Active Contour Segmentation, (d) Segmentation with ASM.

Untuk mengetahui akurasi dari metode segmentasi bidang paru dilakukan dengan membandingkan hasil segmentasi paru menggunakan metode Active Shape Model (ASM) dengan hasil segmentasi paru oleh groundtruth. Proses segmentasi organ paru oleh groundtruth dilakukan dengan menandai pada batas tepi paru pada citra CT Scan asli menggunakan program *Paint*. Untuk menghitung akurasi, sensitivitas dan spesifisitas dari segmentasi organ paru dilakukan dengan cara menambahkan data citra hasil segmentasi menggunakan ASM dengan citra hasil segmentasi oleh groundtruth. Selanjutnya piksel-piksel yang terdeteksi dikelompokkan ke dalam 4 kelompok : TP (*true positive*), TN (*true negative*), FP (*false positive*) dan FN (*false negative*). TP adalah piksel paru yang terdeteksi dengan benar sebagai piksel paru. TN adalah piksel bukan paru yang teridentifikasi dengan benar sebagai piksel bukan paru. FP adalah piksel bukan paru yang teridentifikasi sebagai piksel paru. Sedangkan FN adalah piksel paru yang tidak terdeteksi. Kemudian untuk menguji performa dari metode segmentasi yang diusulkan, dengan cara menghitung akurasi, sensitivitas dan spesifisitas. Akurasi menunjukkan performa dari metode yang diusulkan. Sensitivitas menunjukkan proporsi piksel paru yang terdeteksi dengan benar. Sedangkan spesifisitas menunjukkan proporsi piksel bukan paru yang tidak salah terdeteksi sebagai paru. Persamaan dari akurasi, sensitivitas dan spesifisitas adalah sebagai berikut :

$$Akurasi = \frac{TP+TN}{TP+FP+FN+TN} \quad (35)$$

$$Sensitivitas = \frac{TP}{TP+FN} \quad (36)$$

$$Spesifisitas = \frac{TN}{TN+FP} \quad (37)$$

Hasil pengujian dari segmentasi area paru menggunakan metode ASM ditunjukkan pada Tabel 1.

Tabel 1. Hasil Pengujian Segmentasi Paru Menggunakan Active Shape Model

NO	CITRA	TP	TN	FP	FN	AKURASI	SENSITIFITAS	SPESIFISITAS
						%	%	%
1	0005-000040	21892	90453	1536	384	98,3	98,2	98,3
2	0007-000065	21185	91514	1277	487	98,4	97,7	98,6
3	0008-000024	23493	88616	1667	1471	97,2	94,1	98,1
4	0008-000027	24853	87309	1403	687	98,1	97,3	98,4
5	0011-000026	51388	60803	1515	2094	86,6	96	80
5	0017-000014	40160	71296	3417	805	96,3	98	95,4
6	0018-000003	12401	10028	642	593	98,9	95,4	99,3
7	0019-000012	22529	90086	1647	530	98,1	97,7	98,2
8	0023-000042	33789	77564	2658	1303	96,5	96,2	96,6
9	0023-000055	29811	81816	2004	691	97,6	97,7	97,6
10	0024-000010	22605	89659	1423	1928	97,1	92,1	98,4
11	0024-000013	20292	92038	1574	426	98,2	97,9	98,3


NO	CITRA	TP	TN	FP	FN	AKURASI %	SENSITIFITAS %	SPESIFISITAS %
12	0024-000050	22570	89595	1751	1247	97,3	94,7	98
14	0030-000002	20019	92491	1246	445	98,5	97,8	98,6
15	0030-000013	29455	82493	1858	1380	97,1	95,5	97,7
16	0030-000014	30084	81912	2320	1225	96,9	96	97,2
17	0030-000015	29451	82594	2751	972	96,7	96,8	96,7
18	0032-000014	22165	90113	1899	884	97,5	96,11	97,9
19	0034-000044	24850	87148	2330	538	97,5	97,8	97,3
20	0035-000010	15016	97773	1171	372	98,6	97,5	98,8
21	0035-000017	16181	96116	972	297	98,8	98,1	98,9
22	0035-000018	17185	95171	1027	945	98,2	94,7	98,9
23	0035-000029	19769	92624	903	2061	97,4	90,5	99
24	0036-000014	27088	84672	2176	691	97,4	97,5	97,41
25	0036-000019	25637	86397	2951	2038	95,7	92,6	96,6
26	0036-000048	29226	82666	1085	3635	95,9	88,9	98,7
27	0037-000043	24149	87671	1244	1007	98	95,9	98,6
28	0040-000031	24236	88128	1122	717	98,3	97,1	98,7
29	0040-000032	26493	85593	1278	681	98,2	97,4	98,5
30	0040-000062	35093	76453	1667	1343	97,3	96,3	97,8
Rata-Rata						97,2	96	97,4

Hasil perbandingan akurasi metode yang diusulkan dengan metode yang lain ditunjukkan pada Tabel 2.

Tabel 2. Perbandingan Akurasi

Metode Segmentasi	Akurasi	Sensitivitas	Specifitas
<i>Threshold</i>	95.6	97.6	95.1
<i>Active Contour</i>	84.2	96.2	74.3
ASM	97.2	96	97.4

Setelah melakukan segmentasi area paru, langkah kedua di dalam ekstraksi Region Of Interest (ROI) adalah segmentasi citra yang dicurigai sebagai kanker paru (kandidat Kanker) menggunakan proses morfologi. Hasil dari proses segmentasi kandidat kanker paru menggunakan metode morfologi ditunjukkan pada gambar 8.




Gambar 8. Tahapan proses Segmentasi Kandidat Kanker Paru

Untuk mengetahui akurasi dari metode segmentasi kandidat kanker dilakukan dengan membandingkan hasil segmentasi menggunakan metode morfologi dengan hasil segmentasi oleh groundtruth. Proses segmentasi kandidat kanker paru, dilakukan dengan menandai citra yang dicurigai sebagai kelainan (nodul) menggunakan aplikasi Paint. Selanjutnya hasil penandaan dilakukan segmentasi menggunakan matematika morfologi untuk mendapatkan kontur kandidat kanker. Untuk menghitung akurasi, sensitivitas dan spesifisitas dari segmentasi organ paru dilakukan dengan cara menambahkan data citra hasil segmentasi menggunakan matematika morfologi dengan citra hasil segmentasi oleh ground truth yang diubah menjadi tipe data *unsigned integer* (uint8). Selanjutnya piksel-piksel yang terdeteksi dikelompokkan ke dalam 4 kelompok : TP (*true positive*), TN (*true negative*), FP (*false positive*) dan FN (*false negative*). TP adalah piksel kandidat kanker paru yang terdeteksi dengan benar. TN adalah piksel bukan kandidat kanker paru yang teridentifikasi dengan benar. FP adalah piksel bukan kandidat kanker paru yang teridentifikasi sebagai piksel kandidat kanker paru. Sedangkan FN adalah piksel kandidat kanker paru yang tidak terdeteksi. Kemudian untuk menguji performa dari metode segmentasi yang diusulkan, dengan cara menghitung akurasi, sensitivitas dan spesifisitas. Akurasi menunjukkan performa dari metode yang diusulkan. Sensitifitas menunjukkan proporsi piksel paru yang terdeteksi dengan benar. Sedangkan spesifisitas menunjukkan proporsi piksel bukan kandidat kanker paru yang tidak salah terdeteksi sebagai kandidat kanker paru. Hasil dari pengujian yang dilakukan didapatkan nilai akurasi, sensitivitas dan spesifisitas seperti ditunjukkan pada Tabel 3.

Tabel 3. Hasil Pengujian Segmentasi Kandidat Kanker


NO	CITRA	TP	TN	FP	FN	AKURASI	SENSITIFITAS	SPESIFISITAS
						%	%	%
1	PARU-09	1557	112671	6	96	99,9	94,1	99,9
2	PARU-10	3945	111507	432	126	99,5	96,9	99,6
3	PARU-11	5448	110799	432	255	99,4	95,5	99,6
4	PARU-12	8523	109612	6	384	99,6	95,6	99,9
5	PARU-13	11367	108212	678	288	99,1	97,5	99,9
6	PARU-14	12444	107940	621	453	99,1	96,4	99,4
7	PARU-15	13599	107502	711	858	98,7	94	99,3
8	PARU-16	11805	107956	27	171	99,8	98,5	99,9
9	PARU-17	9948	108839	9	72	99,9	99,2	99,9
10	PARU-18	7155	110132	15	441	99,6	94,1	99,9
Rata-Rata						99,4	96,2	99,7

Gambar 9 menunjukkan citra yang dicurigai sebagai kanker (kandidat kanker) yang dihasilkan dari proses ekstraksi ROI yang dirotasi pada sudut 90° , 180° , dan 270° . Hal tersebut dilakukan untuk mendapatkan fitur ciri dari citra kanker tersebut, sehingga akan meningkatkan dalam proses klasifikasi atau deteksi kanker paru.



Gambar 9. Kandidat Kanker Yang Dirotasi

Citra kandidat kanker paru dan artery hasil ekstraksi ROI selengkapnya ditunjukkan pada Gambar 10.



Gambar 10. Citra Kandidat Kanker dan Artery

SIMPULAN

Dari pengujian yang dilakukan didapatkan hasil ekstraksi Region of Interest (ROI) untuk segmentasi area paru menggunakan metode Active Shape Model nilai akurasi sebesar 97.2%, sensitifitas sebesar 96%, dan spesifisitas sebesar 97.4%. Sedang untuk segmentasi kandidat kanker didapatkan nilai akurasi sebesar 94.4%, sensitifitas sebesar 96.2%, dan spesifisitas sebesar 99.7%. Hal ini dapat disimpulkan bahwa ekstraksi Region of Interest menggunakan metode Active Shape Model dan morfologi dapat dijadikan model dalam ekstraksi ROI secara otomatis. Hal ini berdasarkan pada nilai akurasi, sensitifitas dan spesifisitas yang tinggi.

DAFTAR PUSTAKA

- A.Gajdhane, M. V., & L.M, P. D. (2014). Detection of Lung Cancer Stages on CT scan Images by Using Various Image Processing Techniques. *IOSR Journal of Computer Engineering*, 16(5), 28–35. <https://doi.org/10.9790/0661-16532835>.
- Adams, T., Dörpinghaus, J., Jacobs, M., & Steinhage, V. (2018). Automated lung tumor detection and diagnosis in CT Scans using texture feature analysis and SVM. *Communication Papers of the 2018 Federated Conference on Computer Science and Information Systems*, 17, 13–20. <https://doi.org/10.15439/2018f176>.
- Al-taraweih, M. S., Al-habashneh, S., Shaker, N., Tarawneh, W., & Tarawneh, S. (2014). *Lung Cancer Detection using*. 3(7), 1794–1798. <https://doi.org/10.15662/IJAREEIE.2019.0802011>.
- American Lung Association. (2018). *State of Lung Cancer*. <https://www.lung.org/our-initiatives/research/monitoring-trends-in-lung-disease/state-of-lung-cancer/>
- Ankita, R., Kumari, C. U., Mehdi, M. J., Tejashwini, N., & Pavani, T. (2019). Lung cancer image-feature extraction and classification using GLCM and SVM classifier. *International Journal of Innovative Technology and Exploring Engineering*, 8(11), 2211–2215. <https://doi.org/10.35940/ijitee.K2044.0981119>.

- Asuntha, A., Brindha, A., Indirani, S., & Srinivasan, A. (2016). Lung cancer detection using SVM algorithm and optimization techniques. *Journal of Chemical and Pharmaceutical Sciences*, 9(4), 3198–3203.
- Chen, F., Chen, P., Muhammed, H. H., & Zhang, J. (2017). Intravoxel Incoherent Motion Diffusion for Identification of Breast Malignant and Benign Tumors Using Chemometrics. *BioMed Research International*, 2017.
- Colakoglu, B., Alis, D., & Yergin, M. (2019). Diagnostic Value of Machine Learning- Based Quantitative Texture Analysis in Differentiating Benign and Malignant Thyroid Nodules. *Journal of Oncology*, 2019. <https://doi.org/10.1155/2019/6328329>.
- Cootes, T. F., Edwards, G., & Taylor, C. J. (2013). *Comparing Active Shape Models with Active Appearance Models*. January 1999, 18.1-18.10. <https://doi.org/10.5244/c.13.18>.
- Dappa, E., Higashigaito, K., Fornaro, J., Leschka, S., Wildermuth, S., & Alkadhi, H. (2016). Cinematic rendering – an alternative to volume rendering for 3D computed tomography imaging. *Insights into Imaging*, 7(6), 849–856. <https://doi.org/10.1007/s13244-016-0518-1>
- Gao, X., Su, Y., Li, X., & Tao, D. (2010). A review of active appearance models. *IEEE Transactions on Systems, Man and Cybernetics Part C: Applications and Reviews*, 40(2), 145–158. <https://doi.org/10.1109/TSMCC.2009.2035631>
- Halmos, B., Tan, E. H., Soo, R. A., Cadranel, J., Lee, M. K., Foucher, P., Hsia, T. C., Hochmair, M., Griesinger, F., Hida, T., Kim, E., Melosky, B., Märten, A., & Carcereny, (2019). Impact of afatinib dose modification on safety and effectiveness in patients with EGFR mutation-positive advanced NSCLC: Results from a global real-world study (RealGiDo). *Lung Cancer*, 127(September 2018), 103–111. <https://doi.org/10.1016/j.lungcan.2018.10.028>.
- Hasan Abdulameer, M., A. Mohammed, D., Farhan Rashag, H., & D. Rjeib, H. (2016). A Review Article for Active Appearance Model Fitting Based on Optimization Methods. *Research Journal of Applied Sciences, Engineering and Technology*, 12(10), 1057–1063. <https://doi.org/10.19026/rjaset.12.2825>
- Jeya, I. J. S., & Deepa, S. N. (2016). Lung cancer classification employing proposed real coded genetic algorithm based radial basis function neural network classifier. *Computational and Mathematical Methods in Medicine*, 2016. <https://doi.org/10.1155/2016/7493535>
- Jonker, P. P. (2000). Morphological operations on 3D and 4D images: From shape primitive detection to skeletonization. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 1953 LNCS(March 2001), 371–391. https://doi.org/10.1007/3-540-44438-6_31
- Karargyris, A., Siegelman, J., Tzortzis, D., Jaeger, S., Candemir, S., Xue, Z., Santosh, K. C., Vajda, S., Antani, S., Folio, L., & Thoma, G. R. (2016). Combination of texture and shape features to detect pulmonary abnormalities in digital chest X-rays. *International Journal of Computer Assisted Radiology and Surgery*, 11(1), 99–106. <https://doi.org/10.1007/s11548-015-1242-x>
- Kaufman, A., & Mueller, K. (2005). Overview of volume rendering. *Visualization Handbook*, December, 127–174. <https://doi.org/10.1016/B978-012387582-2/50009-5>
- Kumar, R., Srivastava, R., & Srivastava, S. (2015). Detection and Classification of Cancer from Microscopic Biopsy Images Using Clinically Significant and Biologically Interpretable Features. *Journal of Medical Engineering*, 2015, 1–14. <https://doi.org/10.1155/2015/457906>
- Kustanto, Widodo, S., & Tomo. (2015). Software Development To Detect Lung Nodules in Computed Tomography Scan Image Using Support Vector Machine. *International Research Journal of Engineering and Technology (IRJET)*, 02(06), 354–360. www.irjet.net
- Makaju, S., Prasad, P. W. C., Alsadoon, A., Singh, A. K., & Elchouemi, A. (2018). Lung Cancer Detection using CT Scan Images. *Procedia Computer Science*, 125(2009), 107– 114. <https://doi.org/10.1016/j.procs.2017.12.016>
- Niknam, F., Chen, J., Napaki, S., & Aghmesheh, M. (2011). Approach to multiple pulmonary nodules: A case report and review of literature. *TheScientificWorldJournal*, 11, 760–765. <https://doi.org/10.1100/tsw.2011.74>
- Patil, B. G., & Jain, S. N. (2014). Cancer Cells Detection Using Digital Image Processing Methods. *International Journal of Latest Trends in Engineering and Technology*, 3(4), 45–49.

- Sharma, D., & Jindal, G. (2011). Identifying Lung Cancer Using Image Processing Techniques. *International Conference on Computational Technique and Artificial Intelligence*, 115–120.
- Song, Q. Z., Zhao, L., Luo, X. K., & Dou, X. C. (2017). Using Deep Learning for Classification of Lung Nodules on Computed Tomography Images. *Journal of Healthcare Engineering*, 2017. <https://doi.org/10.1155/2017/8314740>
- Thompson, J. C., Fan, R., Black, T., Yu, G. H., Savitch, S. L., Chien, A., Yee, S. S., Sen, M., Hwang, W. T., Katz, S. I., Feldman, M., Vachani, A., & Carpenter, E. L. (2019). Measurement and immunophenotyping of pleural fluid EpCAM-positive cells and clusters for the management of non-small cell lung cancer patients. *Lung Cancer*, 127(August 2018), 25–33. <https://doi.org/10.1016/j.lungcan.2018.11.020>
- Tian, Y., Shi, Y., & Liu, X. (2012). Recent advances on support vector machines research. *Technological and Economic Development of Economy*, 18(1), 5–33. <https://doi.org/10.3846/20294913.2012.661205>
- Tran, G. S., Nghiem, T. P., Nguyen, V. T., Luong, C. M., Burie, J. C., & Levin-Schwartz, Y. (2019). Improving Accuracy of Lung Nodule Classification Using Deep Learning with Focal Loss. *Journal of Healthcare Engineering*, 2019. <https://doi.org/10.1155/2019/5156416>
- Widodo, S., Rohmah, R. N., & Handaga, B. (2018). Classification of lung nodules and arteries in computed tomography scan image using principle component analysis. *Proceedings - 2017 2nd International Conferences on Information Technology, Information Systems and Electrical Engineering, ICITISEE 2017, 2018-Januari*, 153–158. <https://doi.org/10.1109/ICITISEE.2017.8285485>
- Widodo, S., Rohmah, R. N., Handaga, B., & Arini, L. D. D. (2019). Lung diseases detection caused by smoking using support vector machine. *Telkomnika (Telecommunication Computing Electronics and Control)*, 17(3), 1256–1266. <https://doi.org/10.12928/TELKOMNIKA.V17I3.9799>
- Widodo, S., & Wijiyanto. (2014). Software development for three dimensional visualization of lung on computed tomography scans using active shape model and volume rendering. *Journal of Theoretical and Applied Information Technology*, 65(1), 154–160.
- Zhou, T., Lu, H., Zhang, J., & Shi, H. (2016). Pulmonary nodule detection model based on SVM and CT image feature-level fusion with rough sets. *BioMed Research International*, 2016. <https://doi.org/10.1155/2016/8052436>
- Zhang, Z. (2016). *Derivation of Backpropagation in Convolutional Neural Network (CNN)*. Tennessee : University of Tennessee.