

Original paper

DETEKSI KANKER PARU MENGGUNAKAN SEGMENTASI CITRA CT-SCAN DENGAN ALGORITMA KLUSTER K-MEANS

Ahmad Ridlo Hanifudin Tahier^{*1)}, Aditya Prayugo Hariyanto²⁾M. Much. Azam³⁾

¹ Program Studi Sarjana Terapan Teknologi Rekayasa Otomasi, Sekolah Vokasi, Universitas Diponegoro, Semarang 50275

² Departemen Fisika, Fakultas Sains dan Analitika Data, Institut Teknologi Sepuluh Nopember, Sukolilo Surabaya 60111

³Departemen Fisika, Universitas Diponegoro Semarang, 50275

Email: ridlohanifudin@lecturer.undip.ac.id

Received: 11 April 2023; revised: 2 Juni 2023; accepted: 15 Juli 2023

ABSTRACT

Imaging technology such as Computed Tomography (CT) plays an important role in producing high-resolution images. CT makes it easy for an oncologist to diagnose patients for malignant and benign tumors. However, the technology requires image engineering techniques to make the diagnosis more accurate. The technique to draw that is segmentation. Segmentation plays an important role to distinguish between healthy tissue, benign and malignant tumors. There are segmentation techniques based on mass density (pixel), contour (color) etc. This article will review and explain the development of segmentation techniques specific to lung cancer images. Thresholding segmentation method with k-means clustering using a dataset from The Cancer Imaging Archive (TCIA) named SPIEAAPM Lung CT Challenge dataset is performed in this study. The image data is divided into a number of k clusters that are mutually exclusive of each other. In CT images the value of k is considered as 2 as there are 2 regions, one is lung and other is background. This k-means clustering process will be done in two phases, the first phase k clusters will be formed by taking each pixel intensity value to the nearest centroid by calculating the distance between pixel intensity values to each centroid using different distance calculation methods. The segmentation results show that the accuracy, sensitivity is achieved very well to differentiate and pinpoint the clusters.

Keywords: *Ccomputed Tomography, Thresholding Segmentation, K-means, breast cancer*

ABSTRAK

Teknologi pencitraan *Computed Tomography (CT)* berperan penting untuk menghasilkan citra beresolusi tinggi. CT memberikan kemudahan bagi dokter onkologis untuk mendiagnosa pasien tumor. Namun, teknologi tersebut membutuhkan teknik rekayasa citra agar diagnosis menjadi lebih akurat. Teknik untuk mendeteksi tepian objek pada citra adalah segmentasi. Segmentasi memainkan peranan penting untuk membedakan antara jaringan sehat, tumor jinak, dan ganas. Teknik segmentasi ada yang berdasarkan kerapatan massa (*pixel*), kontur (warna), dll. Pada artikel ini akan dikaji dan dijelaskan perkembangan teknik segmentasi khusus pada citra kanker paru. Metode segmentasi *thresholding* bersama *k-means* klustering menggunakan dataset dari *The*

Cancer Imaging Archive (TCIA) bernama *SPIEAAPM Lung CT Challenge* dilakukan dalam penelitian ini. Data gambar dibagi menjadi sejumlah k kluster yang saling terpisah satu sama lain. Pada citra CT, nilai k dianggap sebagai 2 karena ada 2 daerah, yaitu paru-paru dan latar belakang. Proses pengelompokan k -means ini dilakukan dalam dua fase, yang pertama fase k kluster akan dibentuk dengan mengambil setiap nilai intensitas *pixel* ke centroid terdekat dengan menghitung jarak antara nilai intensitas *pixel* ke setiap centroid menggunakan metode perhitungan jarak yang berbeda. Hasil segmentasi menunjukkan bahwa akurasi sensitivitas dicapai dengan sangat baik untuk membedakan dan menunjukkan lokasi dari sel kanker di paru-paru dengan modalitas CT-scan.

Kata Kunci: *Computed Tomography*, Segmentasi *thresholding*, K-means, Centroid, Kanker Paru-paru

PENDAHULUAN

Kanker paru atau dikenal sebagai karsinoma paru adalah tumor ganas yang ditandai dengan pertumbuhan sel yang tidak terkendali dalam jaringan paru. Sebagian besar kanker yang dimulai di paru adalah karsinoma. Dua tipe utama adalah karsinoma paru sel kecil dan sel tidak kecil (besar) [1]. Merokok jangka panjang adalah faktor utama (sekitar 85%) munculnya kanker paru [2]. Selain itu, sekitar 10 – 15% kasus terjadi karena polusi udara, perokok pasif, asbes, bahan kimia, dan terpapar gas radon [3, 4]. Kanker paru wajib mendapat pengobatan untuk menghindari penyebaran pertumbuhan (metastasis) ke bagian lain dari tubuh. Saat ini, ada beberapa metode yang digunakan untuk pengobatan kanker ini antara lain pembedahan, terapi radiasi, kemoterapi, dan imunoterapi. Sebelum melakukan proses pengobatan, tindakan pencitraan dan diagnosis merupakan langkah sangat penting untuk menentukan jenis pengobatan.

Pemindaian *Computed Tomography* (CT) adalah salah satu teknologi pencitraan medis yang menyajikan informasi yang berguna untuk berbagai diagnosis medis dan klinis [5, 6]. Tujuan utama dalam diagnosis adalah mampu mendeteksi dan

mengklasifikasi dengan benar antara sel kanker dan jaringan normal. Diagnosis terkait tumor sangat bergantung pada kemampuan ahli radiologi untuk membedakan antara tumor jinak dan ganas. Radiologis dapat melakukan interpretasi secara manual, tetapi proses ini kurang efektif untuk karakterisasi kanker paru yang kompleks. Pembacaan citra CT secara manual memang sulit karena citra ditandai dengan adanya noise yang tidak membawa informasi berguna. Noise bisa dijelaskan dengan adanya ketidakrataan dalam distribusi piksel. Karena tidak ada informasi dalam gambar yang jelas membuat deteksi tumor menjadi sulit dan mengakibatkan penentuan letak kanker secara manual tanpa referensi dapat menyebabkan kesalahan dalam estimasi [7].

Penelitian mengenai metode segmentasi sel tumor sudah banyak dilakukan, namun seringkali dokter mempraktikkan segmentasi manual [8] yang bergantung pada operator dan cenderung tidak akurat. Algoritma berbasis *machine learning* memberikan hasil yang lebih baik, tetapi metode tersebut sangat bergantung kepada data referensi. Jika tidak ada data referensi, maka algoritma berbasis pembelajaran mesin tidak dapat diterapkan.

Segmentasi berdasarkan Support Vector Machine (SVM) [8, 9] hanya mengklasifikasikan tumor paru-paru menjadi tipe jinak dan ganas dari gambar dua dimensi (2D). Selain itu, dalam metode berbasis jaringan syaraf tiruan (JST) [10] Self Organizing Maps (SOM) dan Gray Level Co-Occurrence Matriks (GLCM) digunakan untuk segmentasi tumor pada gambar CT 2D dan hanya dapat mengklasifikasikan menjadi tumor jinak dan ganas. Sebagai tambahan, perbandingan antara Fuzzy C Means (FCM), kluster K-means, dan kluster Gustafson-Kessel (GK) menunjukkan bahwa GK lebih baik untuk segmentasi tumor 2D dan kluster k-means memberikan hasil yang lebih baik daripada FCM [11, 12]. Itu sebabnya kami memilih pendekatan segmentasi gambar berbasis K-means untuk penelitian ini.

Segmentasi adalah proses membagi gambar menjadi bagian-bagian atau objek-objek dalam suatu gambar. Setelah pembagian gambar selesai, informasi yang diekstraksi dari gambar tersegmentasi berguna dalam aplikasi Computer Vision. Pembagian gambar tergantung pada penggunaan dan didefinisikan sebagai pengelompokan berdasarkan piksel dengan nilai intensitas yang sama dalam suatu gambar. Kemudian objek atau bagian dipisahkan menjadi objek yang diinginkan dan tidak diinginkan dari gambar asli. Aplikasi gambar segmentasi adalah untuk membantu diagnosis medis [13], deteksi objek seperti jalan, hutan, tanaman, tugas-tugas pengenalan seperti pengenalan wajah [14], pengenalan sidik jari [15], dan deteksi jumlah kendaraan. Juga, segmentasi gambar digunakan di daerah preprocessing gambar seperti kompresi gambar dan estimasi batas objek dalam gambar.

METODE PENELITIAN

Segmentasi kanker paru yang dilakukan menggunakan dataset dari The Cancer Imaging Archive (TCIA) bernama dataset SPIE AAPM Lung CT Challenge. Ini adalah dataset yang mencakup 22.489 citra CT dari 70 pasien yang disimpan dalam format Digital Imaging and Communications in Medicine (DICOM), yang digunakan oleh banyak peneliti untuk segmentasi tumor paru-paru. Meta-data dari gambar CT juga termasuk jarak pixel dan ketebalan setiap irisan. Pada penelitian ini, kami hanya menggunakan satu data set dengan nomor ID Lungx-CT054 dengan diagnosis final suspicious malignant nodule dengan jumlah nodule 2. Secara keseluruhan analisis data ini menggunakan software python 3.11.5 dengan IDE Spyder 5.4.3 berbasis algoritma K-means yang diadopsi dari (Howard) Po-Hao Chen.

Persiapan File DICOM untuk Analisis Hounsfield Unit (HU)

Nilai ambang batas CT number dalam Hounsfield unit (HU) harus ditetapkan untuk segmentasi bagian udara dan bagian non udara lainnya seperti paru-paru, lemak, air, darah, otot, dan tulang. Dalam studi ini, tidak perlu menentukan ambang nilai abu-abu, window width, dan window level. Hanya ambang CT number yang diperlukan untuk analisis kuantitatif. Oleh karena itu, setiap slice file DICOM baru dimasukkan dalam bentuk list setelah pemrosesan gambar berbasis HU dengan perangkat lunak Python selesai [16]. Pemrosesan gambar ini dibuat secara semi otomatis. Oleh karena itu, selama data memiliki nilai kemiringan dan intersep, kita dapat mengubah nilai voxel menjadi HU. Baik intersep skala ulang dan slope yang disimpan dalam header DICOM pada saat akuisisi gambar. Nilai-nilai ini tergantung pada alat

pencitraan, sehingga informasi HU referensi dari data eksternal sangat diperlukan.

Dilation dan Erosion

Kami menggunakan operasi dilation dan erosion secara bersamaan untuk segmentasi paru-paru dari *background* dan menghapus bagian udara pada citra 3D. Ide dasar dalam morfologi biner ini adalah untuk menyelidiki suatu gambar dengan bentuk yang sederhana yang telah ditentukan. Selain itu, untuk menggali dan memperluas bentuk, operasi dilation dijalankan menggunakan elemen struktur. Operasi erosion menggunakan elemen struktur untuk menyelidiki dan mengikis bentuk yang terkandung dalam gambar input. Persamaan (1) dan (2) masing-masing mendefinisikan dilatasi umum dan erosi [17].

$$D(j, k) = B(j, k) \oplus S(j, k) \quad (1)$$

$$E(j, k) = B(j, k) \ominus S(j, k) \quad (2)$$

Dimana $B(j,k)$ untuk nilai $1 \leq j, k \leq r, c$ dan $[r, c]$ mendefinisikan sebagai [baris, kolom] dari gambar biner dan $S(j,k)$. Untuk $1 \leq j, k \leq L$, dimana L adalah bilangan integer ganjil dan $L \leq \min(r, c)$.

Algoritma K-Means

Kluster berarti sekelompok elemen serupa yang memiliki nilai intensitas gambar rentang dekat. Suatu gambar dibagi menjadi sejumlah k kluster yang saling terpisah satu sama lain. Pada awalnya pengguna memberikan jumlah kluster yaitu k . Pada citra CT nilai k dianggap sebagai 2 karena ada 2 daerah, satu paru-paru dan lainnya adalah latar belakang. Proses pengelompokan k -means ini akan dilakukan dalam dua fase, yang pertama fase k kluster akan dibentuk dengan mengambil setiap nilai intensitas piksel ke centroid terdekat dengan

menghitung jarak antara nilai intensitas piksel ke setiap centroid menggunakan metode perhitungan jarak yang berbeda. Pada fase kedua, rata-rata dari masing-masing kluster akan dihitung dan hasilnya disebut sebagai centroid baru. Kedua fase ini kan diulang sampai tidak ada perubahan nilai centroid. Oleh karena itu metode k -means disebut sebagai metode berulang [18, 19].

K-Means adalah algoritma klustering paling sederhana dan konvensional dalam analisis, yang dikenal sebagai algoritma kluster k -means [20]. Keakuratan metode ini sepenuhnya tergantung pada pemilihan centroid kluster. Jadi sangat penting untuk memilih centroid kluster yang optimal untuk mendapatkan hasil yang baik. Jarak Euclidean adalah ukuran yang digunakan untuk memisahkan dataset [21]. Piksel dibagi kedalam kluster individu berdasarkan jarak Euclidean-nya. Fungsi objektif yang digunakan dalam algoritma ini adalah

$$J(v) = \sum_{i=1}^C \sum_{j=1}^{C_i} (||x_i - v_j||)^2 \quad (3)$$

di mana x_i adalah *pixel*, v_j adalah pusat kluster, dan $|x_i - v_j|$ adalah jarak *Euclidean* antara x_i dan v_j , C_i adalah jumlah titik data untuk kluster ke- i , dan C adalah jumlah pusat kluster [6].

Langkah-langkah untuk memulai:

Pilih secara acak k pusat kluster,

$$C = c_1, c_2, c_3, \dots, c_k$$

Hitung jarak di setiap titik data ke masing-masing pusat

Tetapkan titik data ke pusat kluster, yang jaraknya dari titik data minimum dari semua pusat kluster.

Perbarui pusat kluster dengan menggunakan persamaan:

$$v_i = \frac{1}{N_{i,j}} \sum_{j=1}^{N_{i,j}} x_{ij} \quad (4)$$

Di mana v_i adalah i^{th} pusat kluster, N_{ij} adalah jumlah dari titik data yang ditetapkan ke i^{th} ke pusat kluster dan x_{ij} adalah titik data yang ditetapkan dari pusat kluster. Proses tersebut diulangi sampai fungsi objek menjadi minimum.

HASIL DAN PEMBAHASAN

Hasil Konversi File DICOM untuk Analisis HU

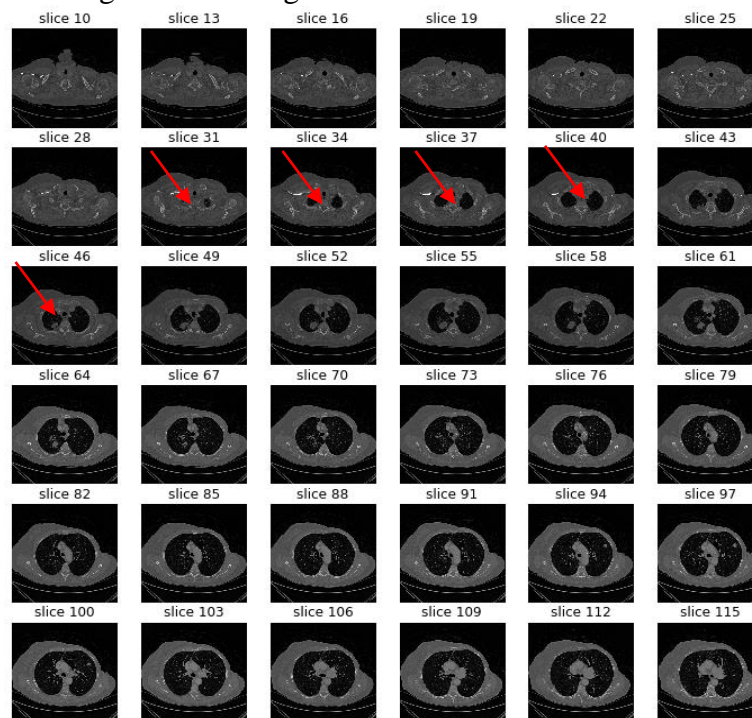
Data DICOM Lungx-CTx054 yang kami gunakan berjumlah 309 slice dengan diagnosis final suspicious malignant nodule dengan jumlah nodul sebanyak dua pada posisi (374, 218).

Berdasarkan Gambar 1, terlihat ada nodul sel kanker pada slice 46-64 untuk nodul kecil. Sedangkan untuk nodul terbesar berada pada slice 206 – 222 yang ditunjukkan oleh Gambar 2. Nodul-nodul ini kemudian menjadi area yang kami gunakan sebagai


input algoritma klustering K-Means. Ada dua jenis kluster yang kami gunakan yaitu kluster 2 dan kluster 4. Sebelum menggunakan kluster yang digunakan, kami perlu mengetahui komponen dari citra paru-paru dengan menggunakan analisis HU berdasarkan piksel.

Analisis HU


Analisis HU berhasil dijalankan dengan software Python 3.11.5 yang ditunjukkan oleh Gambar 3. Berdasarkan Gambar 3, komposisi penyusun citra di dominasi oleh komponen udara dengan nilai HU adalah -1000, sedangkan puncak kedua adalah air dengan HU 0, dan sisanya adalah lemak, otot, darah, dan hati dengan masing-masing HU (-100 sampai -50), dan 10 – 40, 30 – 70, dan 40 – 60. Hasil ini sesuai mengingat data yang digunakan adalah CT-Paru yang penyusun utamanya adalah udara.



Gambar 1. Hasil konversi data DICOM menjadi data tipe Float slice 10 – 115.



Gambar 2. Hasil konversi data DICOM menjadi data tipe Float slice 190-260.

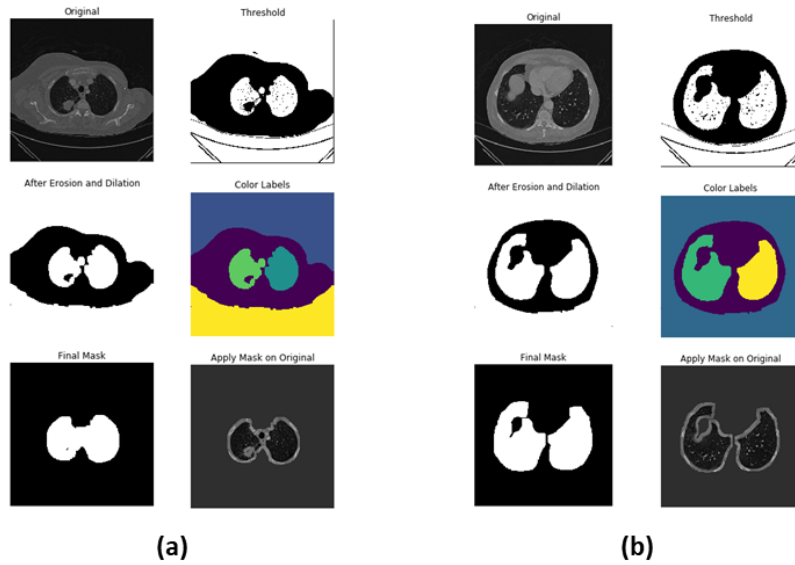


Gambar 3. Hasil Analisis Hounfield Unit (HU) di paru-paru.


Hasil Analisis Segmentasi K-Means K=2

Setelah proses klustering, kami menerapkan threshold dengan nilai parameter 1 dan 0.


Tujuan kami mengubah intensitas citra hanya menjadi dua, nilai intensitas citra yang lebih dari satu atau sama dengan nilai threshold diubah menjadi 1 (berwarna putih), dan nilai intensitas citra yang kurang dari nilai threshold diubah menjadi 0 (berwarna hitam). Hasil segmentasi menunjukkan citra yang jelas untuk membedakan dan menunjukkan letak sel kanker untuk slice (50) dan (210) (Gambar 4). Selain itu kami juga mensegmentasi semua slice berdasarkan Gambar 1 dan 2 untuk menguji sensitivitas dan akurasi algoritma k-means yang digunakan. Hasil ditunjukkan oleh Gambar 5 dan 6.



Gambar 4. Hasil segmentasi dengan menggunakan algoritma K-Means Kluster 2 (a) segmentasi citra untuk Slice- 50 dan (b) segmentasi citra Slice 210.



Gambar 5. Hasil segmentasi K-Means untuk Slice 50-225.

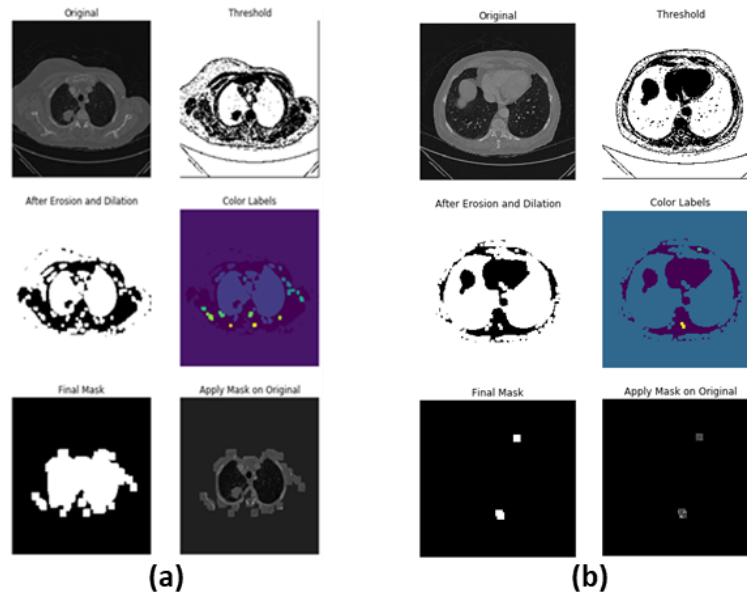


Gambar 6. Hasil segmentasi K-Means untuk Slice 190-305.


Hasil Analisis Segmentasi K-Means K=4

Selain itu, kami juga ingin melihat segmentasi citra k-means dengan kluster 4. Hasil segmentasi ditunjukkan oleh Gambar 7, yang menunjukkan bahwa letak sel kanker sama seperti dengan Gambar 4. Ini

mengindikasikan bahwa akurasi, sensitivitas dicapai dengan sangat baik untuk membedakan dan menunjukkan lokasi dari sel kanker di paru-paru dengan modalitas CT-scan. Di sisi lain, kami juga menyajikan analisis untuk keseluruhan slice yang ditunjukkan oleh Gambar 8.



Gambar 7. Hasil segmentasi dengan menggunakan algoritma K-Means Kluster 4 (a) slice 50 dan (b) slice 220.



Gambar 8. Segmentasi K-means Slice 50-225

KESIMPULAN

Untuk menemukan teknik optimal untuk segmentasi gambar citra paru-paru, teknik segmentasi yang berbeda ditinjau dalam berdasarkan Tujuan, metode yang digunakan, fungsionalitas, set data yang digunakan, dan hasil. Dapat disimpulkan dari perbandingan bahwa sebagian besar teknik pada dasarnya diterapkan pada kumpulan data yang tersedia untuk umum (miniMIAS, DDSM, BI-RAD, dan privat) untuk segmen otot dada, Region of Interest (ROI), lesi atau massa paru-paru yang tidak normal, massa, dan mikrokalsifikasi. Beberapa teknik kuat untuk menangani kontras rendah, noise, tepi buram, dan variasi intensitas dilakukan. Di sisi lain, beberapa teknik memberikan akurasi sangat tinggi untuk dataset tertentu. Ini dapat

dimanfaatkan untuk meningkatkan hasil yang lebih optimal dan dapat mengatasi kekurangan untuk teknik lain [21–36].

Berdasarkan ulasan beberapa artikel yang ditinjau pentingnya segmentasi, aspek tujuan, metode, dan hasil yang dicapai dapat disimpulkan bahwa ada beberapa bagian dari paru-paru yang dihilangkan untuk mempermudah proses segmentasi yakni pemisahan otot dada dengan paru-paru dilakukan dalam proses ini. Sebelum proses segmentasi dilakukan, terlebih dahulu kualitas citra ditingkatkan seperti meningkatkan kontras rendah, citra yang blur dan juga menghilangkan noises. Proses segmentasi memainkan peranan yang sangat penting untuk membedakan apa itu tumor ganas atau jinak yang membantu diagnosis.

Berbagai teknik yang telah disebutkan dapat dimodifikasi sesuai kebutuhan untuk meningkatkan akurasi dan juga menyesuaikan kebutuhan kita saat ini.

DAFTAR PUSTAKA

- [1] Asuntha A, Brindha A, Indirani S, Andy S. Lung cancer detection using SVM algorithm and optimization techniques. *Journal of Chemical and Pharmaceutical Sciences*. 2016;9(4):3198–3203.
- [2] Kurkure M & Thakare A. Introducing automated system for Lung Cancer Detection using Evolutionary Approach. *Int J Eng Comput Sci*. 2016;5(5):16736-16739.
- [3] Rani B & Goel AK. A modified approach for lung cancer detection using bacterial forging optimization Algorithm. *International Journal of Scientific Research Engineering & Technology*. 2016;5(1):39-42.
- [4] Mansoor A, Bagci U, Foster B, et al. Segmentation and Image Analysis of Abnormal Lungs at CT: Current Approaches, Challenges, and Future Trends. *Radiographics*. 2015;35(4):1056-1076.
- [5] Senthil Kumar K, Venkatalakshmi K, Karthikeyan K. Lung Cancer Detection Using Image Segmentation by means of Various Evolutionary Algorithms. *Comput Math Methods Med*. 2019;2019:4909846
- [6] Sarker P, Shuvo MdMH, Hossain Z, Hasan S. Segmentation and classification of lung tumor from 3D CT image using K-means clustering algorithm. 2017 4th International Conference on Advances in Electrical Engineering (ICAEE). 2017:731–736. doi: 10.1109/ICAEE.2017.8255451.
- [7] Kurup M, Bailur A, Rajeswaran P, Sundararajan M, Abhinav. An innovative approach to monitor brain tumor propagation and track the efficacy of treatment by processing MR Images. 2015 International Conference on Industrial Instrumentation and Control (ICIC). 2015:897–901. doi: 10.1109/IIC.2015.7150870.
- [8] Jun Wang, Xia Liu, Di Dong, et al. Prediction of malignant and benign of lung tumor using a quantitative radiomic method. *Annu Int Conf IEEE Eng Med Biol Soc*. 2016;2016:1272-1275.
- [9] Rendon-Gonzalez E & Ponomaryov V. Automatic Lung nodule segmentation and classification in CT images based on SVM. 2016 9th International Kharkiv Symposium on Physics and Engineering of Microwaves, Millimeter and Submillimeter Waves (MSMW). 2016:1–4. doi: 10.1109/MSMW.2016.7537995.
- [10] Dandil E, Çakıroğlu M, Ekşi Z, Özkan M, Kurt OK, Canan A. Artificial Neural Network-Based Classification System for Lung Nodules on Computed Tomography Scans. 6th International Conference on Soft Computing and Pattern Recognition (SoCPaR). 2014:382-386. doi: 10.1109/SOCPAR.2014.7008037.
- [11] Afshar P, Ahmadi A, Zarandi MHF. Lung tumor area recognition in CT images based on Gustafson-Kessel clustering. 2016 IEEE International Conference on Fuzzy Systems (FUZZ-

- IEEE). 2016:2302–2308. doi: 10.1109/FUZZ-IEEE.2016.7737980.
- [12] Kanungo T, Mount DM, Netanyahu DS, Piatko CD, Silverman R, Wu AY. An efficient k-means clustering algorithm: analysis and implementation. *IEEE Trans. Pattern Anal. Mach. Intell.* 2002;24(7):881–892.
- [13] Fan Y, Liu P, Tang J, Luo Y, Du Y. Fuzzy entropy based on differential evolution for breast gland segmentation. *Australas Phys Eng Sci Med.* 2018;41(4):1101-1114.
- [14] Kamencay P, Jelšovka D, Zachariasova M. The impact of segmentation on face recognition using the principal component analysis (PCA). *Signal Processing Algorithms, Architectures, Arrangements, and Applications SPA.* 2011: 1–4.
- [15] Karar A & Kaur A. Latent fingerprint recognition and categorization using Multiphase Watershed Segmentation. 2015 Annual IEEE India Conference (INDICON). 2015:1–6. doi: 10.1109/INDICON.2015.7443679.
- [16] Byun SW, Lee SS, Park JY, Yoo JH. Normal Mastoid Air Cell System Geometry: Has Surface Area Been Overestimated?. *Clin Exp Otorhinolaryngol.* 2016;9(1):27-32.
- [17] van den Boomgaard R & van Balen R. Methods for fast morphological image transforms using bitmapped binary images. *CVGIP Graph. Models Image Process.* 1992;54(3):252–258.
- [18] Kar D & Halder S. Early Detection of Brain Tumor by Using K-Means Klustering, Convolutional Neural Network and Support Vector Machine without any Imaging Test. 2019 International Conference on Information Technology (ICIT). 2019:59–64. doi: 10.1109/ICIT48102.2019.00017.
- [19] Dhanve V & Kumar M. Detection of brain tumor using k-means segmentation based on object labeling algorithm. 2017 IEEE International Conference on Power, Control, Signals and Instrumentation Engineering (ICPCSI). 2017:944–951. doi: 10.1109/ICPCSI.2017.8391851.
- [20] Venkatalakshmi K & Shalinie S. Classification of multispectral images using support vector machines based on PSO and K-Means clustering. Proceedings of 2005 International Conference on Intelligent Sensing and Information Processing. 2005:127–133. doi: 10.1109/ICISIP.2005.1529435.
- [21] Venkatalakshmi K & Shalinie S. Multispectral image classification using modified k-Means algorithm. *Neural Netw World.* 2007;17(2):113–120.
- [22] Gardezi SJS, Adjed F, Faye I, Kamel N, Eltoukhy M. Segmentation of pectoral muscle using the adaptive gamma corrections. *Multimed. Tools Appl.* 2017;77:3919-3940.
- [23] Touil A & Kalti K. Iterative fuzzy segmentation for an accurate delimitation of the breast region. *Comput. Methods Programs Biomed.* 2016;132:137–147.
- [24] Gupta B & Tiwari M. A tool supported approach for brightness preserving contrast enhancement and mass segmentation of mammogram images

- using histogram modified grey relational analysis. *Multidimens. Syst. Signal Process.* 2017;28(4):1549–1567.
- [25] Taghanaki SA, Liu Y, Miles B, Hamarneh G. Geometry-Based Pectoral Muscle Segmentation From MLO Mammogram Views. *IEEE Trans. Biomed. Eng.* 2017;64(11):2662–2671.
- [26] Cordeiro F, Bezerra K, Dos Santos W. Random Walker with Fuzzy Initialization Applied to Segment Masses in Mammography Images. 2017 IEEE 30th International Symposium on Computer-Based Medical Systems (CBMS). 2017:156–161. doi: 10.1109/CBMS.2017.40.
- [27] Kozegar E, Soryani M, Behnam H, Salamati M, Tan T. Mass Segmentation in Automated 3-D Breast Ultrasound Using Adaptive Region Growing and Supervised Edge-Based Deformable Model. *IEEE Trans. Med. Imaging.* 2018;37(4):918–928.
- [28] Shi P, Zhong J, Rampun A, Wang H. A hierarchical pipeline for breast boundary segmentation and calcification detection in mammograms. *Comput Biol Med.* 2018;96:178-188.
- [29] Hazarika M & Mahanta LB. A Novel Region Growing Based Method to Remove Pectoral Muscle from MLO Mammogram Images. *Advances in Electronics, Communication and Computing.* 2018:307–316. doi: 10.1007/978-981-10-4765-7_32.
- [30] Hmida M, Hamrouni K, Solaiman B, Boussetta S. Mammographic mass segmentation using fuzzy contours. *Comput Methods Programs Biomed.* 2018;164:131-142.
- [31] Alam N, Oliver A, Denton ERE, Zwiggelaar R. Automatic Segmentation of Microcalcification Klusters. *Medical Image Understanding and Analysis.* 2018;894:251–261. doi: 10.1007/978-3-319-95921-4_24.
- [32] Liu Y, Chen Y, Han B, Zhang Y, Zhang X, Su Y. Fully automatic Breast ultrasound image segmentation based on fuzzy cellular automata framework. *Biomed. Signal Process. Control.* 2018;40:433–442.
- [33] Shen R, Yan K, Xiao F, Chang J, Jiang C, Zhou K. Automatic Pectoral Muscle Region Segmentation in Mammograms Using Genetic Algorithm and Morphological Selection. *J Digit Imaging.* 2018;31(5):680-691.
- [34] Valdés-Santiago D, Martínez R, Leon-Mecias A, Díaz-Romañach M. Mammographic Mass Segmentation Using Fuzzy C-means and Decision Trees. *Articulated Motion and Deformable Objects.* 2018;10945. doi: 10.1007/978-3-319-94544-6_1.
- [35] Wu N, et al. Breast Density Classification with Deep Convolutional Neural Networks. 2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2018:6682–6686. doi: 10.1109/ICASSP.2018.8462671.
- [36] Dhungel N, Carneiro G, Bradley AP. A deep learning approach for the analysis of masses in mammograms with minimal user intervention. *Med Image Anal.* 2017;37:114-128.