

Klasifikasi Keganasan Kanker Paru Menggunakan Algoritma Propagasi Balik pada Citra CT-Scan

Classification of Malignancy of Lung Cancer Using Backpropagation Algorithm on CT-Scan Images

Evi Pania Putri, Nurhasanah^{*}, Dwiria Wahyuni, Hasanuddin, Riza Adriat, Ya' Muhammad Arsyad

Program Studi Fisika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Tanjungpura

*E-mail: nurhasanah@physics.untan.ac.id

ABSTRACT

In this study, we investigate the classification of lung cancer CT scan images based on malignancy level using a backpropagation artificial neural network (ANN). Lung cancer is a deadly disease characterized by the growth of abnormal lung cells. The proposed method involves preprocessing to enhance image quality, followed by feature extraction using the Gray Level Co-occurrence Matrix (GLCM) method with angle variations of 0° , 45° , 90° , 135° , and $d=1$. The extracted features include energy, contrast, correlation, and homogeneity. The energy value range in malignant cancer is 0.27 to 0.81, while in benign cancer it is 0.26 to 0.73. The contrast in benign cancer ranges from 1.38 to 11.87, while in malignant cancer it is 1.47 to 13.67. The image correlation for malignant cancer is between 0.63 to 0.94, while for benign cancer it is 0.69 to 0.96. Homogeneity in malignant cancer has a value range between 0.67 to 0.91, while in benign cancer it ranges from 0.70 to 0.92. The classification of lung cancer malignancy is restricted to benign and malignant levels using a network architecture of [4 10 2], maximum iteration of 100000, and learning rate of 0.001. The accuracy of the testing data from the ANN is between 90% and 100%. These results demonstrate the effectiveness of the GLCM method and backpropagation algorithm in accurately classifying the malignancy level of lung cancer, which could aid in the early detection and treatment of the disease.

Keywords: Lung cancer, image classification, GLCM, backpropagation.

PENDAHULUAN

Paru adalah organ yang berperan penting dalam sistem pernapasan manusia dan dapat terserang kanker paru jika memiliki kebiasaan buruk seperti merokok. Merokok menjadi salah satu sumber penyebab kanker paru dengan persentase penderita sebesar 90,41% berstatus perokok aktif (Novisari *et al.*, 2014). Adanya korelasi positif antara konsumsi rokok dan kanker paru dapat disimpulkan bahwa merokok meningkatkan risiko kanker paru (Lucas & Harris, 2018). Tercatat pada tahun 2020, penderita kanker paru mencapai hampir 35 ribu kasus baru dan menjadi penyakit dengan tingkat kematian tertinggi di Indonesia dengan angka kematian sebesar 31 ribu penderita (Globocan 2020). Kesalahan diagnosis di awal pemeriksaan dapat memperburuk kondisi penderita karena gejala awal kanker paru yang mirip dengan pilek dan alergi. Oleh karenanya, perlu dilakukan pemeriksaan lebih lanjut dengan menggunakan pencitraan medis untuk mengkonfirmasi diagnosis.

Salah satu modalitas pencitraan medis yang sering digunakan untuk diagnosis kanker adalah

mesin *Computed Tomography Scan* (CT-Scan). CT-Scan dapat menggambarkan kondisi satu organ maupun keseluruhan tubuh manusia (Sumijan *et al.*, 2019). Namun, penggunaan CT-Scan menghasilkan ratusan citra dalam satu kali pemeriksaan sehingga menambah beban kerja ahli medis bilamana citra tersebut diamati secara manual (Makaju *et al.*, 2018). Pembacaan manual bisa saja menyebabkan kurangnya konsistensi dan keakuratan dalam melakukan pembacaan citra pada kasus yang sama dengan pasien berbeda. Oleh karena itu, diperlukan pemanfaatan kecerdasan buatan seperti Jaringan Saraf Tiruan (JST) untuk pengolahan citra digital agar meringankan kerja ahli medis.

Penggunaan JST dengan metode propagasi balik untuk pengolahan citra digital kanker paru banyak dilakukan karena dianggap mudah dalam melakukan pemrograman. Berbagai studi telah dipelajari menggunakan metode propagasi balik seperti identifikasi citra *Chest X-Ray* (CXR) kanker paru dengan hasil akurasi sebesar 75% (Andayani *et al.*, 2019), analisis citra CT-Scan kanker paru dengan hasil akurasi sebesar 95,918 % (Akkar & Haddad, 2020), dan deteksi

citra CT-Scan kanker paru dengan hasil akurasi sebesar 94,89 % (Shankara & Hariprasad, 2022). Penelitian terdahulu ini, hanya sebatas membedakan antara citra normal dan citra kanker paru saja. Adapun klasifikasi citra CT-Scan berdasarkan tingkat keganasan kanker paru juga telah pernah dilakukan dengan hasil akurasi sebesar 83% (Silvana *et al.*, 2020), namun belum menggunakan fitur GLCM untuk mengekstraksi ciri dari citra yang digunakan.

Berbeda dengan penelitian yang sudah ada, pada penelitian ini digunakan JST metode propagasi balik untuk mengklasifikasi citra CT-Scan kanker paru berdasarkan tingkat keganasannya (jinak dan ganas). Klasifikasi akan dilakukan berdasarkan ekstraksi ciri yang diperoleh dengan GLCM.

METODE

Data

Citra CT-Scan paru diunduh dari laman cancerimagingarchive.net dengan format .dcm yang kemudian diubah menjadi .png untuk diproses. Pemilihan format .png bertujuan untuk kemudahan pemantauan citra karena gambar dengan format .png tidak memerlukan aplikasi tambahan untuk membuka gambarnya. Citra CT-Scan dikelompokkan ke dalam data pelatihan dan data pengujian. Spesifikasi ukuran citra yang digunakan adalah 720×720 piksel. Data latih berjumlah 40 citra yang terdiri dari 20 citra kanker ganas dan 20 citra kanker jinak. Sementara itu, data uji terdiri dari 10 citra kanker ganas dan 10 citra kanker jinak. Data ini dianggap memadai untuk keperluan pelatihan dan pengujian dalam pemanfaatan Jaringan Saraf Tiruan berbasis Propagasi Balik untuk mengklasifikasi tingkat keganasan kanker.

Preprocessing Citra

Proses perbaikan citra dilakukan dalam 2 tahap, yaitu distribusi histogram dan segmentasi citra.

a. Ekualisasi Histogram

Ekualisasi histogram adalah proses penyesuaian histogram pada citra digital dengan memetakan histogram, sehingga jumlah piksel pada setiap derajat keabuan relatif sama. Ekualisasi histogram dilakukan untuk meningkatkan kontras citra sehingga mudah diidentifikasi selama proses klasifikasi. Pendekatan yang diambil adalah fokus pada wilayah dengan tingkat piksel yang tinggi dan mengurangi rentang keabuan pada wilayah dengan jumlah piksel yang lebih rendah. Dampaknya dapat dimanfaatkan untuk meningkatkan kontras secara keseluruhan (Anraeni & Herman, 2018).

Optimasi kontras dimaksudkan untuk meningkatkan kontras citra dengan mereplikasi seluruh rentang nilai piksel, sehingga perbedaan antara piksel-piksel yang berdekatan menjadi lebih nyata (Dijaya 2023). Pemerataan histogram diharapkan dapat menyeimbangkan variasi intensitas

piksel menjadi lebih seimbang sehingga memungkinkan GLCM lebih efektif dalam mengekstraksi informasi tekstur dari berbagai tingkat keabuan dalam citra.

Penerapan ekualisasi histogram pada citra CT scan paru dapat meningkatkan kontras dan menonjolkan nodul yang dapat menjadi tanda keberadaan sel kanker. Peningkatan kontras difokuskan pada area tulang belakang. Pemberian mask pada area citra yang memiliki gambaran tulang belakang bertujuan mengurangi gangguan visual dan memberikan solusi yang lebih baik dan memudahkan deteksi.


b. Segmentasi Citra

Segmentasi citra merujuk pada proses pemisahan objek satu dengan yang lain dalam suatu citra atau antara objek dengan latar yang ada dalam citra tersebut. Segmentasi citra merupakan tahapan pengolahan yang ditujukan untuk memisahkan objek dari latar belakang. Hal ini dilakukan untuk memudahkan analisis objek dalam hal ini adalah citra paru (Heryanto *et al.*, 2020).

Citra yang disamakan kemudian akan disegmentasi yang bertujuan untuk memisahkan citra dari latar belakang. Hasil segmentasi adalah citra yang sudah mencakup area paru dan memungkinkan analisis lebih fokus pada area paru. Tujuannya adalah pada saat proses GLCM menjadi lebih terfokus dan efektif. Proses segmentasi dilakukan menggunakan kodingan dalam Bahasa pemrograman python.

Ekstraksi Ciri Menggunakan GLCM

Fitur statistik yang dihitung dalam proses mengekstraksi sifat adalah energi, kontras, korelasi dan homogenitas. Variasi sudut yang digunakan adalah 0° , 45° , 90° , 135° (Gambar 1) dan jarak ketetanggaan piksel adalah satu ($d=1$) (Lamasigi, 2021).



Gambar 1. Matriks GLCM

Energi adalah skala keseragaman suatu citra. Citra dengan pencahayaan tinggi cenderung memiliki nilai energi yang lebih besar daripada citra dengan pencahayaan rendah. Untuk menghitung energi tersebut dapat digunakan persamaan (1) (Saitem *et al.*, 2016).

$$E = \sum_{i,j} (p(i,j))^2 \quad (1)$$

Kontras citra menunjukkan sebaran terang gelapnya citra, yang dihitung menggunakan persamaan (2) (Saitem *et al.*, 2016).

$$Con = \sum_{i,j} |i - j|^2 p(i, j) \tag{2}$$

Korelasi adalah skala ketergantungan linier derajat keabuan (Saitem *et al.*, 2016). Nilai korelasi suatu citra akan tinggi jika unsur-unsurnya acak begitu pun sebaliknya, yang dihitung menggunakan persamaan (3).

$$Corr = \sum_{i,j} \frac{(i - \mu_i)(i - \mu_j)p(i, j)}{\sigma_i \sigma_j} \tag{3}$$

Homogenitas dapat menunjukkan tingkat keseragaman variasi dalam intensitas citra, yang dihitung menggunakan persamaan (4) (Saitem *et al.*, 2016).

$$H = \sum_{i,j} \frac{p(i, j)}{1 + |i - j|} \tag{4}$$

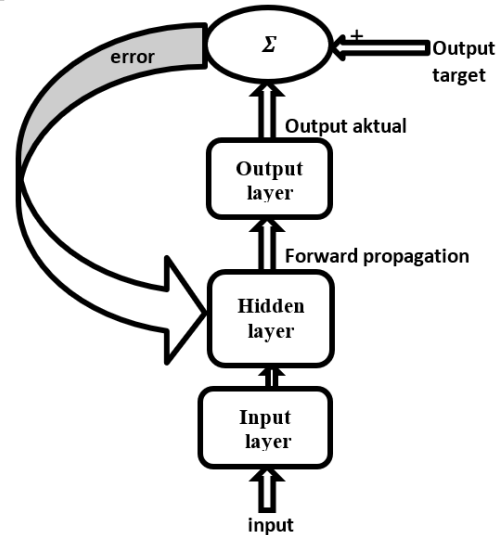
Klasifikasi Citra Menggunakan Propagasi Balik

Klasifikasi data dilakukan dengan mengelompokkan data menjadi data pelatihan dan data pengujian. Proses pelatihan dilakukan guna mempelajari dan mengevaluasi model jaringan yang dibuat. Validasi diperoleh dari hasil perbandingan *output* jaringan dengan informasi yang melekat pada data referensi. Gambar 2 menunjukkan alur kerja algoritma propagasi balik. Nilai pada lapisan *input* akan dilakukan propagasi maju sampai memperoleh nilai keluaran pada lapisan *output*. Neuron pada setiap jaringan akan diaktifkan dan dinonaktifkan menggunakan fungsi aktivasi. Keluaran dari lapisan *output* disebut juga *output* aktual. *Output* aktual akan dibandingkan dengan nilai target untuk menentukan *error*. Jika masih ada *error* maka akan dilakukan propagasi balik pada JST yang dibuat.

Data citra CT Scan yang digunakan merupakan data citra yang diunduh melalui situs <https://wiki.cancerimagingarchive.net/display/Public/LIDC-IDRI>. Data tersebut telah dikelompokkan berdasarkan stadium kanker paru-paru. Citra-citra CT-Scan, setelah diunduh, diacak urutannya dan disatukan ke dalam satu kelompok untuk proses pengolahan selanjutnya. Proses pengolahan citra dilakukan untuk memastikan bahwa data yang digunakan sudah siap untuk tahap pelatihan dan pengujian pada jaringan propagasi balik.

Setelah proses pengolahan selesai, citra-citra tersebut akan digunakan untuk melakukan pelatihan dan pengujian pada jaringan propagasi balik. Jaringan propagasi balik ini merupakan model yang digunakan untuk klasifikasi citra CT-Scan berdasarkan stadium kanker paru-paru. Hasil klasifikasi yang diperoleh dari model tersebut akan dievaluasi menggunakan data yang diperoleh dari *website* dataset resmi tersebut. Evaluasi ini bertujuan untuk mengukur sejauh mana model dapat mengklasifikasikan citra CT-Scan dengan akurasi yang tinggi, serta

memberikan wawasan tentang performa dan keandalan model dalam konteks deteksi kanker paru-paru.




Gambar 2. Alur kerja algoritma propagasi balik

HASIL DAN PEMBAHASAN

Hasil Preprocessing citra


Proses memperoleh informasi yang terkandung dalam citra adalah dengan memproses citra. Citra yang akan diproses harus melalui proses *preprocessing* untuk peningkatan kualitas citra.



Gambar 3. Citra Paru dengan (a) *benign* dan (b) *malignant*.

Hal ini dilakukan agar citra mudah diolah dan dianalisis dengan menggunakan berbagai metode pengolahan citra. Histogram citra adalah grafik dari distribusi setiap piksel yang dimiliki oleh citra.

Gambar 4 menampilkan citra organ paru yang mengalami tahapan *preprocessing*. Gambar 4(a) menunjukkan citra CT-Scan kanker paru berukuran 512x512 yang merupakan citra mentah dari organ paru. Gambar 4(b) adalah citra yang diberi mask berukuran 300x400 piksel, secara spesifik menandai bagian citra yang akan mengalami proses ekualisasi histogram.



Gambar 4. Proses *preprocessing* pada citra paru: (a) citra mentah, (b) bagian citra yang diekualisasi, (c) citra hasil ekualisasi histogram, dan (d) citra hasil segmentasi.

Proses pemberian *mask* bertujuan untuk memfokuskan ekualisasi pada area tertentu dari citra. Setelah pemberian *mask*, dilakukan proses ekualisasi histogram pada Gambar 4(c), menghasilkan citra organ paru utuh berukuran 512x512 piksel. Proses ini meningkatkan distribusi intensitas piksel secara merata di seluruh citra, memberikan representasi visual yang lebih baik dari berbagai struktur dan fitur dalam organ paru. Gambar 4(d) menunjukkan hasil segmentasi pada citra, di mana proses ini memungkinkan identifikasi dan pemisahan struktur atau area tertentu dalam organ paru. Segmentasi dapat memberikan informasi lebih lanjut tentang daerah-daerah yang penting atau menarik perhatian dalam konteks analisis citra medis kanker paru.

Histogram ini mewakili distribusi setiap piksel yang dimiliki oleh citra. Penyebaran histogram citra umumnya tidak seragam untuk seluruh bagian citra. Ekualisasi histogram diharapkan dapat menyeimbangkan variasi intensitas penyebaran piksel (Yulianti *et al.*, 2021).

Selain ekualisasi histogram, peningkatan kualitas citra dilakukan dengan metode segmentasi citra agar tidak ada tumpang tindih antara nilai tekstur, warna dan tingkat homogenitas suatu citra. Gambar 5 menunjukkan grafik ekualisasi histogram pada citra paru dengan garis merah sebagai histogram awal citra paru dan garis biru sebagai histogram ekualisasi. Citra yang telah diseragamkan


histogram disegmentasi dengan nilai *thresholding* ($T=127$). Keluaran citra dari hasil *thresholding* ditunjukkan pada Gambar 4(d). Segmentasi citra dapat meningkatkan akurasi jaringan berkurangnya tumpang tindih antar karakteristik homogen pada citra. Nilai ambang (T) yang digunakan pada citra adalah 127. Artinya, piksel dengan nilai keabuan di atas ambang 127 akan dianggap sebagai bagian dari suatu daerah, sementara yang di bawah ambang akan dianggap sebagai bagian dari daerah lain. Citra hasil *thresholding* ditunjukkan pada Gambar 4(d).

Secara fisika penentuan batas ambang dilakukan menggunakan persamaan berikut (Heryanto *et al.*, 2020) :

$$T = \frac{f_{maks} - f_{min}}{2} \quad (2.1)$$

$$f(x, y) = 255, \text{ jika } f(x, y) > T \quad (2.2)$$

$$f(x, y) = 0, \text{ jika } f(x, y) < T \quad (2.3)$$



Gambar 5. Grafik ekualisasi histogram

Ekstraksi Ciri pada Citra Paru

Hasil ekstraksi fitur dengan metode GLCM ditunjukkan pada Gambar 6. Hasil ekstraksi fitur pada citra menjadi ciri khas yang membedakan antara kanker jinak dan kanker ganas. Sebaran nilai energi ditunjukkan pada Gambar 6(a). Distribusi nilai energi dari citra kanker paru menunjukkan kanker ganas memiliki lebih sedikit energi dibanding citra kanker jinak. Gambar 6(b), 6(c), dan 6(d) berturut-turut menunjukkan penyebaran nilai kontras, korelasi dan homogenitas yang menunjukkan bahwa terdapat beberapa citra yang memiliki nilai kontras, korelasi dan homogenitas yang rendah. Hal tersebut diakibatkan beberapa citra kanker masih memiliki komposisi yang terlalu terang atau terlalu gelap. Hasil ekstraksi ini yang menjadi identitas citra masukan.

Sebaran energi pada citra kanker jinak terletak di antara 0,26 hingga 0,73, sementara pada kanker ganas, sebaran energinya mulai dari 0,28 hingga 0,81. Hal ini disebabkan oleh penyebaran sel kanker yang lebih luas pada





kanker ganas, yang tercermin dalam frekuensi kemunculan derajat sejenis yang lebih tinggi dalam citra.

Gambar 6(b) menunjukkan bahwa citra kanker ganas cenderung memiliki nilai kontras yang lebih tinggi daripada citra kanker jinak. Sebaran kontras pada citra kanker jinak terletak di antara 1,38 sampai 11,87 sementara pada kanker ganas berkisar antara 1,47 sampai 13,67. Ini menunjukkan bahwa citra kanker ganas memiliki variasi intensitas yang lebih besar, mencerminkan perbedaan struktural yang lebih tajam dalam citra tersebut.

Selanjutnya, nilai korelasi pada citra kanker ganas juga menunjukkan kecenderungan yang lebih rendah daripada citra kanker jinak (Gambar 6(c)). Kisaran nilai korelasi kanker ganas antara 0,63 sampai 0,94, sedangkan kanker jinak berkisar antara 0,70 sampai 0,96. Citra kanker ganas, memiliki variasi yang lebih besar dalam struktur dan tekstur, cenderung menunjukkan korelasi yang lebih rendah dibandingkan dengan citra kanker jinak yang mungkin memiliki struktur yang lebih homogen.

Nilai homogenitas pada Gambar 6(d) pada citra kanker ganas berkisar antara 0,67 hingga 0,91, sementara pada citra kanker jinak memiliki rentang nilai antara 0,70 hingga 0,92. Perbedaan ini menunjukkan bahwa citra kanker jinak cenderung memiliki tingkat seragamitas yang sedikit lebih tinggi dibandingkan dengan citra kanker ganas dalam konteks nilai homogenitas.

Nilai ekstraksi karakteristik yang diperoleh dengan menggunakan metode GLCM ini dilakukan pada 4 sudut yaitu 0°, 45°, 90° dan 135°. Identitas citra terlihat paling jelas apabila diekstraksi pada sudut 90° dan 135°. Meskipun demikian, metode GLCM tetap dapat menunjukkan identitas citra dengan baik.



Gambar 6. Grafik penyebaran energi 4 sudut. (a) penyebaran energi, (b) penyebaran kontras, (c) penyebaran korelasi, (d) penyebaran homogenitas

Hasil Klasifikasi Citra dengan JST

JST pada penelitian ini dilatih dengan metode *trial-error*. Pelatihan dilakukan dengan memasukkan nilai-nilai fitur berupa energi, kontras, korelasi dan homogenitas sebagai nilai masukan dan keluaran yang bernilai 0 (kanker jinak) dan 1 (kanker ganas). Model JST yang dibangun memiliki arsitektur [4 10 2], dengan fungsi aktivasi sigmoid biner dan algoritma propagasi balik. Arsitektur [4 10 2] berarti jaringan saraf memiliki 4 lapisan *input* (energi, kontras, korelasi, homogenitas), 10 lapisan tersembunyi dan 2 lapisan *output*. Pada proses pelatihan, nilai masukan dan keluaran sudah ditentukan terlebih dahulu. Namun untuk jumlah lapisan tersembunyi, iterasi maksimum dan laju pembelajaran (α) menjadi parameter yang senantiasa diperbaharui selama pelatihan sampai model jaringan menunjukkan akurasi maksimal.

Tabel 1. Pelatihan jaringan

α	I_{maks}	Akurasi
0,1	1.000	65%
0,1	10.000	77,5%
0,01	100.000	90%
0,01	100.000	100%
0.001	100.000	100%

Algoritma propagasi balik dipilih karena sistem kerjanya yang selalu memperbaharui nilai *error* pada lapisan tersembunyi, sehingga diharapkan mampu memperbesar nilai akurasi. Penentuan jumlah lapisan tersembunyi yang tepat juga sangat mempengaruhi akurasi model jaringan yang dibuat. Namun, jumlah lapisan tersembunyi yang terlalu banyak dapat mempengaruhi waktu satu kali iterasi. Laju pembelajaran berfungsi agar proses pelatihan jaringan menjadi lebih cepat. Berdasarkan Tabel 1, nilai maksimal iterasi berbanding lurus terhadap akurasi jaringan. Artinya semakin besar iterasi maka semakin besar pula akurasi yang didapatkan. Pelatihan jaringan memperoleh akurasi tertinggi pada iterasi maksimum 100000 dan laju pembelajaran 0,001. Oleh karena itu, model jaringan saraf yang dianggap ideal adalah jaringan dengan arsitektur [4 10 2], iterasi maksimum 100000 dan laju pembelajaran 0,001.

Model jaringan yang telah dibuat selanjutnya akan melewati proses pengujian guna menentukan kualitas model jaringan yang dibuat. Data yang telah diuji berjumlah 20 citra yang terdiri dari 10 citra kanker ganas dan 10 citra kanker jinak. Pengujian dilakukan sebanyak 10 kali *running* dengan hasil akurasi jaringan berkisar antara 90% sampai 100%. Analisis hanya menggunakan parameter akurasi sebagai metrik evaluasi dikarenakan model difokuskan pada tingkat keakuratan prediksi. Hasil klasifikasi pada proses pengujian jaringan juga dicocokkan dengan diagnosa pasien yang terdapat di dataset citra.

Tabel 2. Pengujian jaringan

Pengujian	Akurasi
1	90%
2	90%
3	95%
4	97%
5	95%
6	90%
7	90%
8	100%
9	100%
10	100%

Seperti yang ditunjukkan pada Tabel 2, hasil akurasi tertinggi dari jaringan adalah 100% yang terjadi pada pengujian ke-8, 9, dan 10. Hal ini menunjukkan bahwa model jaringan yang telah dibuat mampu mengklasifikasikan data baru dengan baik. Oleh karena hasil yang didapatkan memiliki akurasi sampai 100%, maka penggunaan fitur GLCM untuk ekstraksi ciri pada citra digital CT-Scan sangat baik digunakan. Penggunaan JST dengan metode propagasi balik juga sangat baik untuk mengklasifikasikan tingkat keganasan kanker paru.

KESIMPULAN

Ekstraksi fitur menggunakan metode *Gray Level Co-occurrence Matrix* (GLCM) dapat digunakan untuk mengenali karakteristik suatu citra berupa energi, kontras, korelasi, dan homogenitas. Hasil ekstraksi fitur sebagai masukan bagi jaringan saraf tiruan dapat mengklasifikasikan tingkat keganasan kanker dengan akurasi antara 90% dan 100%.

DAFTAR PUSTAKA

- Akkar, Hanan & Suhad Qasim Haddad. 2020. Diagnosis of Lung Cancer Disease Based on Back-Propagation Artificial Neural Network Algorithm. *Engineering and Technology Journal*. **38**(3B): 184-96.
- Andayani U, Rahmat RF, Syahputra MF, Lubis A & Siregar B. 2019. Identification of Lung Cancer Using Backpropagation Neural Network. *Journal of Physics: Conference Series*. **1361**(1).
- Anraeni, Siska & Herman. 2018. Peningkatan Kualitas Citra Iris Mata Menggunakan Operasi Pikel Dan Ekualisasi Histogram Untuk Pengklasifikasian Kondisi Kesehatan Ginjal. *Seminar Nasional Teknologi Informasi dan Komunikasi STI&K (SeNTIK)*. **2**: 1-6.
- Dijaya R. 2023. *Buku Ajar Pengolahan Citra Digital*. Sidoarjo: UMSIDA Press.
- Globocan. 2020. *Cancer in Indonesia*.
- Heryanto, Agus IW, Artama, Kurniawan MWS & Gunadi GA. 2020. Segmentasi Warna dengan Metode Thresholding. *Wahana Matematika dan Sains*. **14**(1): 54-64.
- Lamasri & Yusrin Z. 2021. DCT untuk Ekstraksi Fitur Berbasis GLCM pada Identifikasi Batik Menggunakan K-NN. *Jambura Journal of Electrical and Electronics Engineering*. **3**(1): 1-6.
- Lucas RM & Harris RMR. 2018. On The Nature

- of Evidence and ‘Proving’ Causality: Smoking and Lung Cancer vs. Sun Exposure, Vitamin D and Multiple Sclerosis.” *International Journal of Environmental Research and Public Health*. **15**(8): 1-13.
- Makaju S, Prasad PWC, Alsadoon A, Singh AK & Elchouemi A. 2018. Lung Cancer Detection using CT Scan Images. *Procedia Computer Science*. **125**(2009): 107-114.
- Saitem, Adi K & Widodo E. 2016. Analisis Citra CT Scan Kanker Paru Berdasarkan Ciri Tekstur Gray Level Co-occurrence Matrix dan Ciri Morfologi Menggunakan Jaringan Syaraf Tiruan Propagasi Balik. *Youngster Physics Journal*. **5**(4): 417-424.
- Shankara C & Hariprasad SA. 2022. Artificial Neural Network for Lung Cancer Detection Using CT Images. *International Journal of Health Sciences*. **6**(March): 2708-2724.
- Silvana, Meza, Akbar R, Gravina H & Firdaus. 2020. Optimization of characteristics using Artificial Neural Network for Classification of Type of Lung Cancer. *2020 International Conference on Information Technology Systems and Innovation, ICITSI 2020 - Proceedings*. 236-241.
- Soeroso NN, Soeroso L & Syafiuddin T. 2014. Kadar Carcinoembryogenic Antigen (CEA) Serum Penderita. *J Respir Indo*. **34**(1): 17-25
- Sumijan S, Purnama AW & Arlis S. 2019. Peningkatan Kualitas Citra CT-Scan dengan Penggabungan Metode Filter Gaussian dan Filter Median. *Jurnal Teknologi Informasi dan Ilmu Komputer*. **6**(6): 591-600.
- Yulianti D, Nurhasanah & Arman Y. 2021. Segmentasi Citra Sel Darah Serviks. *Prisma Fisika*. **9**(1): 1-3.

