Jurnal Ilmu Kesehatan (JIKSAN)

Volume 2 No. 1 (2026) 72-78

ISSN: 3109-1911

Deteksi Otomatis Adenokarsinoma Paru Berbasis Deep Learning di RSP Ario Wirawan Salatiga

Automated Lung Adenocarcinoma Detection Based on Deep Learning at Ario Wirawan Pulmonary Hospital Salatiga

Lilik Lestari[1], Susilo[2], Rudi Setiawan[3*]
[1]Rumah Sakit Paru dr. Ario Wirawan, Salatiga, Indonesia
[2]Universitas Dian Nuswantoro, Semarang, Indonesia
[3]Universitas An Nasher, Cirebon, Indonesia

Email: rudi_setiawan@universitasannasher.ac.id

Article History:
Received: 4 March 2026
Revised: 10 June 2026
Accepted: 18 June 2026

Keyword: *Adenocarcinoma, CNN, Deep Learning, Detection, Lung Cancer*

Abstract

Background: *Lung adenocarcinoma remains a major oncological challenge in Indonesia, making early detection a crucial step for patient survival. However, the manual detection and classification of adenocarcinoma nodules from healthy lung tissue images is time-consuming and prone to inter-observer variability.* ***Purpose:*** *This study aims to develop and evaluate an automated lung adenocarcinoma detection system using Deep Learning at Ario Wirawan Pulmonary Hospital Salatiga.* ***Method:*** *A quantitative experimental approach was utilized with a dataset of 172 training images (100 Normal, 72 Adenocarcinoma) and 130 testing images (100 Normal, 30 Adenocarcinoma).* ***Result:*** *The model's performance was evaluated by tuning hyperparameters, specifically epochs and learning rates. The results showed optimal convergence at epoch 40 with a learning rate of 0.001, achieving a testing accuracy of 95.38%. At this optimum, the model yielded a sensitivity of 0.967 and specificity of 0.95 for the normal class, and a sensitivity of 0.95 and specificity of 0.967 for the adenocarcinoma class. The Deep Learning architecture demonstrated robust performance in handling adenocarcinoma images, providing a precise automated detection tool that significantly enhances diagnostic efficiency and serves as a reliable second opinion for medical professionals.*

Abstrak

Latar Belakang: Adenokarsinoma paru tetap menjadi tantangan onkologi utama di Indonesia, menjadikan deteksi dini sebagai langkah krusial untuk kelangsungan hidup pasien. Namun, identifikasi dan klasifikasi manual nodul adenokarsinoma dari citra jaringan paru sehat memakan waktu dan rentan terhadap variabilitas antar-pengamat. **Tujuan:** Penelitian ini bertujuan untuk mengembangkan dan mengevaluasi sistem deteksi adenokarsinoma paru otomatis menggunakan algoritma Deep Learning di Rumah Sakit Paru dr. Ario Wirawan Salatiga. **Metode:** Pendekatan eksperimental kuantitatif digunakan dengan dataset yang terdiri dari 172 citra latih (100 Normal, 72 Adenokarsinoma) dan 130 citra uji (100 Normal, 30 Adenokarsinoma). Kinerja model dievaluasi melalui penyesuaian hyperparameter, khususnya epoch dan learning rate. **Hasil:** Hasil penelitian menunjukkan konvergensi optimal pada epoch ke-40 dengan learning rate 0,001, mencapai akurasi pengujian sebesar 95,38%. Pada kondisi optimal ini, model menghasilkan sensitivitas 0,967 dan spesifisitas 0,95 untuk kelas normal, serta sensitivitas 0,95 dan spesifisitas 0,967 untuk kelas adenokarsinoma. Arsitektur Deep Learning menunjukkan performa yang tangguh dalam menangani variasi citra adenokarsinoma, menyediakan alat deteksi otomatis presisi yang secara signifikan meningkatkan efisiensi diagnostik dan berfungsi sebagai opini kedua yang andal bagi profesional medis.

PENDAHULUAN

Kanker paru, khususnya subtipe adenokarsinoma, tetap menjadi salah satu tantangan onkologi terbesar di Indonesia dengan tingkat mortalitas yang tinggi. Deteksi dini dan penentuan prognosis melalui modalitas pencitraan *Computed Tomography* (CT-Scan) maupun radiografi konvensional dianggap sebagai langkah krusial yang menentukan tingkat keberhasilan terapi pasien[5,10]. Di Rumah Sakit Paru Dr. Ario Wirawan (RSPAW) Salatiga, sebagai pusat rujukan kesehatan respirasi nasional, volume pemeriksaan citra paru sangat tinggi. Namun, proses identifikasi nodul adenokarsinoma dari jaringan paru secara manual memakan waktu dan rentan terhadap variabilitas antar-pengamat. Pemanfaatan algoritma *Machine Learning* dan *Deep Learning* telah terbukti secara sistematis mampu membedakan fitur visual yang esensial, meningkatkan presisi diagnostik serta penyusunan rencana perawatan medis pada kanker paru[1,3].

Di tingkat nasional, perkembangan algoritma *Convolutional Neural Network* (CNN) untuk analisis citra medis tumbuh sangat pesat. Berbagai penelitian terkini di institusi rujukan seperti RSPHC Surabaya dan RSUD dr. Syaiful Anwar menunjukkan bahwa arsitektur CNN terbukti andal dalam mendeteksi dan mengklasifikasikan penyakit paru hingga tingkat mutasi genetik dari data lokal[4,7]. Secara global, model kecerdasan buatan telah mendominasi literatur terkait diagnosis kanker paru berbasis citra medis[16], dan kemajuan metodologi komputasinya bahkan telah mencapai tahap yang dapat memprediksi invasi patologis praoperasi, seperti halnya prediksi STAS (*Spread Through Air Spaces*) pada adenokarsinoma paru[2].

Meskipun teknologinya sangat menjanjikan, adopsi klinis *Artificial Intelligence* (AI) di Indonesia masih dihadapkan pada beberapa tantangan mendasar. Terdapat kesenjangan regulasi hukum terkait penggunaan sistem cerdas dalam keputusan diagnostik medis, yang menuntut pengembangan sistem dengan model pertanggungjawaban berlapis dan kelayakan sebagai *Software as a Medical Device* (SaMD)[11]. Selain itu, tenaga medis sangat membutuhkan pendekatan *Explainable AI* (XAI) agar rasionalisasi matematis algoritma pendeteksi kanker dapat diterjemahkan menjadi wawasan visual yang mudah dipahami[6,12]. Implementasi teknis ini mengukuhkan kebutuhan untuk tidak sekadar menciptakan model komputasi yang akurat, tetapi juga model yang tangguh dan selaras dengan standar alur kerja radiologi terkini[8].

Berdasarkan kondisi tersebut, terdapat urgensi untuk melakukan hilirisasi penelitian *Deep Learning* yang lebih mendalam dan spesifik terhadap kasus adenokarsinoma di fasilitas nyata seperti RSPAW. Penelitian ini bermaksud mengisi celah (*gap*) tersebut dengan mengembangkan purwarupa sistem deteksi otomatis adenokarsinoma paru. Inovasi (*novelty*) dari studi ini terletak pada pemanfaatan dan optimasi *hyperparameter* langsung menggunakan karakteristik dataset citra RSPAW. Diharapkan model ini mampu dioperasikan sebagai pilar opini kedua (*second opinion*) guna mengatasi masalah beban kerja dokter, dengan mempertahankan standar ketepatan identifikasi klasifikasi tumor paru secara kuantitatif yang presisi.

METODE PENELITIAN

Penelitian ini menggunakan pendekatan Kuantitatif Eksperimental. Fokus utamanya adalah menguji efektivitas algoritma *Deep Learning* (CNN) dalam melakukan deteksi dan klasifikasi citra adenokarsinoma paru. Eksperimen dilakukan dengan melatih model menggunakan data historis yang bersumber dari arsip Instalasi Radiologi RSPAW Salatiga yang idealnya dapat diintegrasikan melalui ekosistem *server* PACS (*Picture Archiving and Communication System*)[8]. Pengambilan sampel dilakukan menggunakan teknik *Purposive Sampling* yang mencakup variasi citra paru. Dataset evaluasi penelitian ini terdiri atas 172 data latih (100 Normal, 72 Adenokarsinoma) dan 130 data uji (100 Normal, 30 Adenokarsinoma) yang ditunjukkan oleh Gambar 1.



a. Normal b. Adenokarsinoma

Gambar 2. Dataset evaluasi penelitian, a. Normal dan b. Adenokarsinoma

Prosedur penelitian diawali dengan pra-pemrosesan citra yang meliputi penyesuaian ukuran (*resizing*) menjadi dimensi seragam serta normalisasi nilai piksel. Citra masukan tersebut kemudian diumpankan ke dalam rancangan model CNN. Untuk mengatasi permasalahan seperti *memory overfitting* pada set data yang tidak terlalu besar, dilakukan rekayasa optimasi melalui pengujian secara komprehensif terhadap dua *hyperparameter* fundamental, yaitu variasi jumlah *epoch* (5, 10, 20, 40) dan modifikasi laju pembelajaran atau *learning rate* (1; 0,1; 0,01; 0,001)[9,13]. Hasil probabilitas klasifikasi dianalisis secara kuantitatif dengan berfokus pada metrik *confusion matrix* yang menghasilkan skor Akurasi, Sensitivitas, serta Spesifisitas untuk menentukan reliabilitas klinis deteksi tersebut, detail alur penelitian ditunjukkan Gambar 2.



Gambar 2. Flowchart Tahapan Metode Penelitian

HASIL

Bagian ini menyajikan karakteristik performa hasil pelatihan dan pengujian dari arsitektur klasifikasi *Deep Learning* yang dirancang untuk deteksi adenokarsinoma paru. Analisis kinerja model dikelompokkan ke dalam dua skenario pengujian utama: evaluasi pengaruh variasi jumlah siklus pelatihan (*epoch*) dan analisis sensitivitas laju pembelajaran (*learning rate*), tampilan pengujian ditunjukkan oleh Gambar 3.

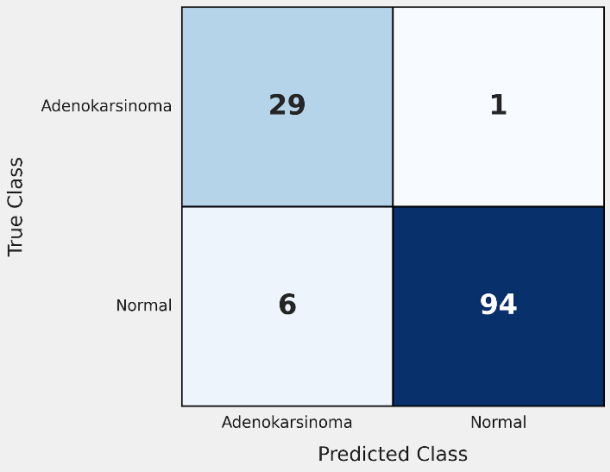

Total Accuracy: 94.62%

Kelas	Sensitivitas	Spesifisitas
Adenokarsinoma	0.9667	0.9400
Normal	0.9400	0.9667

Raw Confusion Matrix Data:

	Adenokarsinoma	Normal
Adenokarsinoma	29	1
Normal	6	94

a. Hasil Confusion Matrix b. Hasil Analisis Uji Diagnostik

Gambar 3. Salah Satu Pengujian Model Deep Learning dengan Data Uji Adenokarsinoma (epoch 20 dan lerning rate 0,001), a. Hasil Confusion Matrix dan b. Hasil Analisis Uji Diagnostik.

Pengaruh Variasi Epoch

Tahap pertama pengujian berfokus pada observasi tren konvergensi algoritma seiring dengan bertambahnya jumlah *epoch*. Pada skenario ini, laju pembelajaran (*learning rate*) ditetapkan konstan pada angka 0,001. Hasil eksperimen menunjukkan adanya perbaikan pengenalan pola yang sejalan dengan peningkatan siklus pembelajaran. Peningkatan iterasi membuahkan hasil optimal pada epoch 40 di mana akurasi pelatihan mencapai 100% dan akurasi pengujian berada di puncak konvergensi sebesar 95,38%. Stabilitas hasil uji pada epoch 40 mengindikasikan bahwa model telah berhasil menemukan titik konvergensi terbaiknya tanpa terjebak pada kondisi *overfitting* yang berlebih, selaras dengan pendekatan *ensemble* dan optimasi parameter pada model segmentasi kanker paru lainnya[14].

Tabel 1. Kinerja Model Berdasarkan Variasi Epoch (L Rate = 0,001)

Epoch	Akurasi Pelatihan (%)	Akurasi Pengujian (%)	Kelas Target	Sensitivitas	Spesifisitas
5	88,95	84,62	Normal	1	0,80
			Adenokarsinoma	0,80	1
10	96,51	91,54	Normal	0,97	0,90
			Adenokarsinoma	0,90	0,97
20	100,00	94,62	Normal	0,97	0,94
			Adenokarsinoma	0,94	0,97
40	100,00	95,38	Normal	0,97	0,9
			Adenokarsinoma	0,95	0,97

Pengaruh Variasi Learning Rate

Analisis bivariat dilakukan dengan memodifikasi laju pembelajaran pada titik ekuilibrium (epoch 20). Parameter ini sangat krusial dalam menentukan besaran pembaruan bobot dalam

jaringan CNN. Pada tingkat pembelajaran yang ekstrem (LR = 1), model mengalami anomali matematis dan gagal memetakan fitur, tercermin dari akurasi uji yang jeblok di angka 23,08%. Sebaliknya, pengaturan tingkat pembelajaran ke ukuran eksponensial yang lebih kecil membuktikan bahwa penyesuaian graduasi (LR 0,01 dan 0,001) jauh lebih presisi dibandingkan iterasi besar. Laju 0,001 mengokohkan performa terbaik di akurasi uji 94,62%.

Tabel 2. Kinerja Model Berdasarkan Variasi Learning Rate (Epoch = 20)

Learning Rate	Akurasi Pelatihan (%)	Akurasi Pengujian (%)	Kelas Target	Sensitivitas	Spesifisitas
1	41,86	23,08	Normal	1	0
			Adenokarsinoma	0	1
0,1	80,81	84,62	Normal	0,867	0,84
			Adenokarsinoma	0,84	0,87
0,01	100	94,62	Normal	0,97	0,94
			Adenokarsinoma	0,94	0,97
0,001	100	94,62	Normal	0,97	0,94
			Adenokarsinoma	0,94	0,97

PEMBAHASAN

Temuan dari eksperimen komputasi ini menegaskan kemampuan unggul dari arsitektur *Deep Learning* dalam mengekstraksi dan mendeteksi sel anomali adenokarsinoma, termasuk pengenalan terhadap nodul samar berwujud *Ground-Glass Nodules* (GGNs) dari citra paru yang kompleks[17]. Dari aspek durasi pelatihan, teramati bahwa arsitektur klasifikasi komputasional membutuhkan kuantitas iterasi yang cukup tinggi. Model baru mencapai titik presisi terkuatnya pada ambang batas 40 epoch (akurasi 95,38%), yang mana peningkatan ini krusial untuk menyeimbangkan angka sensitivitas dan spesifisitas pada kedua kelas identifikasi.

Eksplorasi terhadap parameter *learning rate* menunjukkan betapa sensitifnya algoritma pada koreksi bobot gradien. Lompatan koreksi besar merusak struktur pengenalan, di mana model sama sekali tidak mampu mengenali ciri paru adenokarsinoma dengan benar (sensitivitas adenokarsinoma bernilai 0). Penurunan ukuran langkah ke spektrum eksponensial di bawah 0,1 mengembalikan kapabilitas prediksi yang sangat solid. Ketahanan dan tingginya skor metrik sensitivitas ini dapat difungsikan untuk mendongkrak ketajaman klasifikasi, yang mana keefektifannya sejalan dengan implementasi sukses *artificial intelligence* pada analisis histopatologi kanker paru menggunakan metode prediksi berbasis gradien visual pada dataset medis komprehensif[15,18].

Dibandingkan dengan penandaan visual murni, konfigurasi arsitektur CNN pada Epoch 40 dengan LR 0,001 mampu mendongkrak ketajaman identifikasi Adenokarsinoma hingga memiliki sensitivitas 0,95 dan spesifisitas 0,97. Otomatisasi dengan keandalan setinggi ini berimplikasi sangat luas karena dapat membuka jalan bagi integrasi algoritma *Deep Learning* sebagai instrumen dukungan klinis yang konkret bagi tenaga medis di RSPAW Salatiga. Keandalan algoritma semacam ini akan mempercepat prosedur evaluasi radiologi yang secara tidak langsung menyelamatkan jadwal antrean pasien tanpa harus mengkompromikan presisi diagnosa akhir medis.

KESIMPULAN

Studi ini membuktikan bahwa rancangan kecerdasan buatan berbasis *Deep Learning* sangat andal dalam melakukan deteksi dan klasifikasi otomatis pada citra adenokarsinoma paru multiresolusi. Puncak kapabilitas model berhasil dicapai melalui penyesuaian dinamis parameter konstan komputasi pada 40 *epoch* bersanding dengan *learning rate* 0,001. Kombinasi ini menorehkan akurasi uji final sebesar 95,38%, yang didukung oleh proporsi keseimbangan identifikasi kelas adenokarsinoma dengan metrik sensitivitas 0,95 dan

spesifisitas 0,97. Ke depan, hasil studi pendahuluan ini sangat potensial untuk diaplikasikan ke tahap praktis sebagai instrumen perangkat lunak pendukung medis (*Software as a Medical Device*/SaMD), sehingga memperingkas alur kerja sembari mematuhi prinsip regulasi serta mempertahankan standar klinis tertinggi di pusat pelayanan respirasi utama.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih yang sebesar-besarnya kepada Kementerian Kesehatan Republik Indonesia melalui Rumah Sakit Paru dr. Ario Wirawan (RSPAW) Salatiga atas dukungan institusional yang telah diberikan. Akses terhadap basis data citra medis serta kelancaran fasilitas yang disediakan oleh instalasi terkait sangat berkontribusi krusial dalam proses pelatihan maupun validasi model komputasi pada penelitian ini. Penulis juga mengapresiasi seluruh tenaga medis profesional yang telah memberikan saran klinis selama proses pengembangan sistem deteksi ini.

DAFTAR PUSTAKA

Zhang, X., Liu, J., Zhou, W., Lu, J., Wu, L., Li, Y., ... & Cai, J. (2025). Deep learning enhances precision diagnosis and treatment of non-small cell lung cancer: future prospects. Translational Lung Cancer Research, 14(8), 3196-3215.

Fan, Y., Niu, R., Gao, J., Sun, Y., Feng, J., Zhu, Y., ... & Wang, Q. (2025). New Advances in Imaging-Based Preoperative Prediction of STAS in Lung Adenocarcinoma: From CT and PET/CT to Radiomics and Deep Learning. Academic Radiology.

Abumohsen, M., Costa-Montenegro, E., García-Méndez, S., Owda, A. Y., & Owda, M. (2026). Machine Learning and Deep Learning in Lung Cancer Diagnostics: A Systematic Review of Technical Breakthroughs, Clinical Barriers, and Ethical Imperatives. AI, 7(1), 23.

Wahyuningrum, R. T., Bauravindah, A., Siradjuddin, I. A., Satoto, B. D., Sari, A. K., & Sensusiati, A. D. (2025). Enhancing Lung Disease Diagnosis with Deep-Learning-Based CT Scan Image Segmentation. Intelligent Systems with Applications, 200565.

Iqlessias, F., & Sudharmadji. (2026). Prognosis Adenokarsinoma Paru Stadium Lanjut Berdasarkan Modalitas CT Scan dan X-Ray Thoraks: Sebuah Laporan Kasus. JRI (Jurnal Radiografer Indonesia), 9(1), 14-20.

Fotopoulos, D., Ladakis, I., Filos, D., Moreno-Sánchez, P. A., van Gils, M., & Chouvarda, I. (2026). Explainable AI in Cancer Imaging: Scoping Review of Methods, Modalities, and Clinical Integration. Journal of Medical Internet Research, 28, e80645.

Zhang, L., LaBelle, W., Unberath, M., Chen, H., Hu, J., Li, G., & Dreizin, D. (2023). A vendor-agnostic, PACS integrated, and DICOM-compatible software-server pipeline for testing segmentation algorithms within the clinical radiology workflow. Frontiers in medicine, 10, 1241570.

Ishola, B. O., Olaleye, C. O., Adedokun, D. A., Toyobo, O. J., & Adedokun, S. A. (2026). Metaheuristic-Optimized Deep Learning for Lung Cancer Detection: A Systematic Review of Convolutional Neural Network Approaches. International Journal of Research and Scientific Innovation (IJRSI), 13(4).

Kusumawardhani, E., & Yasir, A. P. (2025). The Relationship Between Risk Factors and EGFR Mutation in Lung Adenocarcinoma Patients. Journal of Syntax Literate, 10(11).

Muhafid, Ariyanto, C., Giman, A. W., Triana, G. A., Pratama, P. A., & Sapsudin, A. (2026).

Pertanggungjawaban pidana atas penyalahgunaan teknologi kecerdasan buatan dalam diagnosis dan perawatan kesehatan.

Maulana, I. (2024). Explainable AI-Driven TabNet Model Enhanced with Bayesian Optimization for Lung Cancer Prediction and Interpretation. Jurnal Riset Informatika, 7(1), 8–20.

Shariff, V., Paritala, C., & Ankala, K. M. (2025). Optimizing non small cell lung cancer detection with convolutional neural networks and differential augmentation. Scientific Reports, 15(1), 15640.

Mahmud, M. R., Fardin, H., Siddiqui, M. I. H., Sakib, A. H., & Al Sakib, A. (2025). Hybrid deep learning for interpretable lung cancer recognition across computed tomography and histopathological imaging modalities. International Journal of Science and Research Archive [Internet], 1798-810.

Vanitha, K. R. M. T., R, M. T., Sree, S. S., & Guluwadi, S. (2024). Deep learning ensemble approach with explainable AI for lung and colon cancer classification using advanced hyperparameter tuning. BMC Medical Informatics and Decision Making, 24(1), 222.

Abdullahi, K., Ramakrishnan, K., & Ali, A. B. (2025). Deep learning techniques for lung cancer diagnosis with computed tomography imaging: A systematic review for detection, segmentation, and classification. Information, 16(6), 451.

Xue, W., & Chen, J. (2026). Artificial intelligence construction: a review of the bridge between CT imaging features of lung ground-glass nodules adenocarcinoma and carcinogenic driver genes. Journal of Cancer Research and Clinical Oncology, 152(4), 92.

Pathan, S., Ali, T., PG, S., & Rao, D. (2024). An optimized convolutional neural network architecture for lung cancer detection. APL bioengineering, 8(2).

Kementerian Kesehatan RI. (2025). ASEAN-Japan Medical Devices Regulatory Training 2025: Software as a Medical Device (SaMD) Regulation. Fakultas Farmasi UI. https://farmasi.ui.ac.id/2025/05/elementor-53957/