

KLASIFIKASI CITRA HISTOPATOLOGI KANKER PARU-PARU MENGUNAKAN RESNET50 DENGAN INTERPRETASI GRAD-CAM

Ade Verdaus Saputra, Wahyudi Setiawan

Sistem Informasi, Universitas Trunojoyo Madura
Jalan Raya Telang, Kamal, Bangkalan, Jawa Timur, Indonesia
220441100067@student.trunojoyo.ac.id

ABSTRAK

Kanker paru-paru merupakan salah satu penyebab utama kematian di dunia, sehingga diperlukan metode diagnosis yang cepat, akurat, dan konsisten. Namun, diagnosis histopatologi konvensional masih bergantung pada interpretasi manual patolog terhadap citra berwarna Hematoxylin and Eosin (H&E), yang rentan terhadap subjektivitas, inkonsistensi, dan waktu analisis yang lama. Permasalahan ini mendorong perlunya sistem otomatis yang tidak hanya memiliki performa tinggi, tetapi juga dapat diinterpretasikan secara klinis.

Penelitian ini bertujuan untuk mengimplementasikan dan mengevaluasi arsitektur Convolutional Neural Network ResNet50 dalam mengklasifikasikan citra histopatologi kanker paru-paru serta meningkatkan transparansi keputusan model menggunakan Grad-CAM. Metode penelitian meliputi preprocessing citra, augmentasi data, pembagian dataset secara stratifikatif, pelatihan model menggunakan 5-Fold Cross Validation, evaluasi performa klasifikasi, serta visualisasi interpretabilitas model. Dataset yang digunakan adalah LC25000 dengan tiga kelas, yaitu lung_normal, lung_adenocarcinoma, dan lung_squamous cell carcinoma.

Hasil penelitian menunjukkan bahwa model ResNet50 mencapai akurasi pengujian sebesar 0.9731 dengan nilai precision, recall, dan F1-score yang konsisten tinggi pada seluruh kelas. Visualisasi Grad-CAM mampu menyoroti area patologis yang relevan secara klinis, seperti kepadatan nukleus abnormal dan pola keratinisasi. Hasil ini membuktikan bahwa ResNet50 dengan Grad-CAM efektif sebagai solusi awal sistem pendukung diagnosis histopatologi kanker paru yang akurat dan interpretabel.

Kata kunci : ResNet50, Grad-CAM, Histopatologi, Kanker Paru, Deep Learning.

1. PENDAHULUAN

Kanker paru-paru merupakan salah satu penyakit dengan tingkat mortalitas tertinggi di dunia. Diagnosis dini sangat krusial untuk meningkatkan peluang keberlangsungan hidup pasien, namun proses diagnosis histopatologi masih mengandalkan interpretasi manual terhadap preparat jaringan yang diwarnai Hematoxylin and Eosin (H&E) [1]. Proses ini membutuhkan waktu, sumber daya manusia yang berpengalaman, serta rentan terhadap variabilitas antar-patolog.

Dalam beberapa tahun terakhir, pendekatan kecerdasan buatan, khususnya deep learning, telah menunjukkan potensi besar dalam mendukung otomatisasi analisis citra medis [2]. CNN seperti ResNet, VGG, atau DenseNet terbukti mampu mengekstraksi fitur kompleks dari citra histopatologi. Namun, penerapan CNN untuk domain medis tidak hanya membutuhkan akurasi tinggi, tetapi juga interpretabilitas yang baik. Tanpa kemampuan menjelaskan keputusan model, sistem deep learning berisiko ditolak oleh praktisi klinis.

ResNet50 menjadi salah satu arsitektur yang stabil dan banyak digunakan sebagai baseline model karena kemampuan residual learning yang mempercepat konvergensi dan mencegah vanishing gradient [3]. Pada penelitian ini, ResNet50 digunakan untuk mengklasifikasikan citra histopatologi paru dari dataset LC25000 ke tiga kelas berbeda. Untuk mengatasi isu interpretabilitas, penelitian ini menerapkan Grad-CAM sebagai metode visualisasi

untuk menunjukkan area citra yang berkontribusi terhadap prediksi model [4][5].

Dengan demikian, penelitian ini tidak hanya memfokuskan diri pada performa model, tetapi juga pada transparansi prediksi, yang menjadi kebutuhan utama dalam implementasi deteksi kanker paru-paru untuk ranah medis.

Berdasarkan kebutuhan akan sistem pendukung diagnosis yang akurat dan dapat diinterpretasikan pada analisis citra histopatologi kanker paru-paru, maka permasalahan dalam penelitian ini dirumuskan sebagai berikut: Apakah arsitektur CNN ResNet50 mampu memberikan performa klasifikasi yang akurat dan stabil pada citra histopatologi kanker paru-paru dari dataset LC25000, Apakah metode Grad-CAM mampu meningkatkan interpretabilitas model dengan menampilkan area citra yang berkontribusi secara signifikan terhadap keputusan klasifikasi.

Tujuan dari penelitian ini adalah mengevaluasi kinerja arsitektur ResNet50 dalam melakukan klasifikasi citra histopatologi kanker paru-paru menggunakan dataset LC25000 berdasarkan metrik akurasi, precision, recall, dan F1-score. Mengimplementasikan dan mengevaluasi metode Grad-CAM sebagai pendekatan interpretabilitas untuk memvisualisasikan area citra yang berkontribusi terhadap keputusan klasifikasi model.


Untuk menjawab permasalahan penelitian dan mencapai tujuan yang telah ditetapkan, penelitian ini dirancang dengan tahapan menggunakan dataset histopatologi kanker paru-paru LC25000 yang terdiri

dari tiga kelas, yaitu adenocarcinoma, squamous cell carcinoma, dan jaringan normal, Melakukan preprocessing citra yang meliputi resize, normalisasi, dan augmentasi data untuk meningkatkan kualitas dan keragaman data pelatihan, Menerapkan arsitektur ResNet50 sebagai model utama untuk klasifikasi citra, dengan evaluasi performa menggunakan strategi 5-Fold Cross Validation, Mengukur kinerja model berdasarkan metrik akurasi, precision, recall, dan F1-score serta menganalisis stabilitas kurva training dan validation, Mengintegrasikan metode Grad-CAM untuk memvisualisasikan area citra yang berkontribusi terhadap prediksi model dan menilai relevansi klinis dari hasil visualisasi tersebut.

2. TINJAUAN PUSTAKA

2.1. Citra Histopatologi Kanker Paru

Citra histopatologi kanker paru-paru yang diwarnai menggunakan Hematoxylin and Eosin (H&E) merupakan representasi visual utama dalam diagnosis kanker berbasis jaringan. Pewarnaan Hematoxylin menyoroti struktur nukleus sel dengan warna biru keunguan, sedangkan Eosin mewarnai sitoplasma dan matriks ekstraseluler dengan warna merah muda. Kombinasi ini memungkinkan identifikasi detail morfologi sel dan arsitektur jaringan, seperti pada gambar 1.



Gambar 1. Citra Histopatologi Kanker paru-paru

Perbedaan pola antara jaringan normal, adenocarcinoma, dan squamous cell carcinoma mencakup variasi struktur glandular, keratinisasi, pleomorfisme, dan kepadatan sel abnormal[5]. Pada jaringan normal paru, struktur alveolar tampak teratur dengan distribusi sel yang homogen. Sebaliknya, adenocarcinoma ditandai oleh pembentukan struktur glandular yang tidak beraturan, peningkatan kepadatan nukleus, serta pleomorfisme sel. Squamous cell carcinoma menunjukkan ciri khas berupa keratinisasi, jembatan interseluler, dan perubahan lapisan epitel yang signifikan. Kompleksitas pola morfologi ini menjadikan analisis citra histopatologi sebagai tugas yang menantang dan sangat bergantung pada keahlian patolog

2.2. Deep Learning pada Domain Medis


Deep learning telah banyak diterapkan dalam bidang medis untuk tugas segmentasi, klasifikasi, dan deteksi penyakit, khususnya pada analisis citra radiologi dan histopatologi. Convolutional Neural Network (CNN) menjadi pendekatan dominan karena kemampuannya dalam mengekstraksi fitur hierarkis

mulai dari tepi sederhana hingga pola kompleks tingkat tinggi [6].

Dalam konteks histopatologi, CNN mampu menangkap karakteristik tekstur, distribusi warna, serta struktur mikro jaringan yang sulit direpresentasikan menggunakan metode ekstraksi fitur konvensional. Namun demikian, tantangan utama penerapan deep learning di domain medis bukan hanya pada pencapaian akurasi tinggi, tetapi juga pada keandalan, stabilitas model, serta kemampuan interpretasi hasil prediksi agar dapat diterima oleh praktisi klinis [6].

2.3. ResNet50

ResNet50 merupakan arsitektur CNN yang terdiri dari 50 lapisan dalam dan diperkenalkan untuk mengatasi permasalahan degradasi performa pada jaringan yang sangat dalam. Arsitektur ini menggunakan residual block dengan shortcut connection yang memungkinkan gradien mengalir langsung ke lapisan sebelumnya, sehingga mempercepat konvergensi dan mengurangi risiko vanishing gradient. Pada gambar 2 di bawah merupakan arsitektur dari Resnet50.



Gambar 2. Arsitektur Resnet50

Dalam berbagai penelitian citra medis, ResNet50 terbukti memiliki performa yang stabil dan efektif dalam mempelajari pola-pola mikro seperti tekstur seluler, distribusi nukleus, dan struktur jaringan kompleks [7]. Karakteristik ini menjadikan ResNet50 sebagai salah satu model baseline yang banyak digunakan dalam klasifikasi citra histopatologi, termasuk pada kasus kanker paru-paru [7].

2.4. Data Augmentation

Keterbatasan jumlah data berlabel merupakan permasalahan umum dalam domain medis. Data augmentation digunakan untuk meningkatkan keragaman data pelatihan dengan menerapkan transformasi geometris dan fotometrik tanpa mengubah makna klinis citra. Teknik augmentasi seperti rotasi, flipping, zooming, dan shifting terbukti efektif dalam mengurangi overfitting serta meningkatkan kemampuan generalisasi model.

Dalam analisis citra histopatologi, augmentasi juga membantu model menjadi lebih robust terhadap variasi orientasi jaringan, perbedaan preparasi slide, serta variasi pencahayaan mikroskop.

2.5. Evaluasi Model Klasifikasi


Evaluasi performa model klasifikasi citra medis umumnya dilakukan menggunakan metrik akurasi,

precision, recall, dan F1-score. Akurasi memberikan gambaran umum performa model, sementara precision dan recall lebih relevan dalam konteks medis karena berkaitan dengan tingkat kesalahan diagnosis. Confusion matrix digunakan untuk menganalisis distribusi kesalahan prediksi antar kelas dan mengidentifikasi potensi bias model [3].

Penggunaan beberapa metrik secara bersamaan diperlukan untuk memberikan evaluasi yang komprehensif terhadap kinerja model klasifikasi kanker paru-paru [3].

2.6. Grad-CAM

Gradient-weighted Class Activation Mapping (Grad-CAM) merupakan metode visualisasi yang digunakan untuk meningkatkan interpretabilitas model CNN. Grad-CAM bekerja dengan memanfaatkan gradien dari kelas target terhadap feature map pada lapisan konvolusi terakhir untuk menghasilkan heatmap yang menunjukkan area citra yang paling berpengaruh terhadap prediksi model, seperti pada gambar 3.



Gambar 3. Ilustrasi Grad-CAM

Heatmap ini menampilkan area penting yang mempengaruhi prediksi model. Dalam domain medis, Grad-CAM berperan penting sebagai alat verifikasi untuk memastikan bahwa model mengambil keputusan berdasarkan area patologis yang relevan secara klinis, bukan berdasarkan artefak atau noise citra. Oleh karena itu, integrasi Grad-CAM menjadi langkah penting dalam pengembangan sistem pendukung diagnosis berbasis deep learning [8].

2.7. Penelitian Terdahulu

Beberapa penelitian terdahulu telah mengkaji penerapan deep learning dan teknik interpretabilitas dalam klasifikasi kanker paru-paru, baik pada citra radiologi maupun citra medis lainnya.

Huang mengusulkan pendekatan integrasi Vision Transformer (ViT) dengan algoritma machine learning untuk klasifikasi nodul paru menggunakan citra CT-scan. Penelitian tersebut menunjukkan bahwa model berbasis transformer mampu menangkap dependensi global pada citra CT dan memberikan performa klasifikasi yang robust. Namun, fokus penelitian ini terbatas pada citra radiologi (CT imaging) dan tidak membahas analisis citra histopatologi yang memiliki karakteristik visual dan kompleksitas morfologi yang berbeda secara signifikan. Selain itu, aspek

interpretabilitas model dalam konteks pengambilan keputusan klinis tidak dibahas secara mendalam.


Mothkur mengembangkan pendekatan klasifikasi kanker paru menggunakan beberapa arsitektur Deep CNN yang dikombinasikan dengan metode Grad-CAM untuk meningkatkan interpretabilitas model. Hasil penelitian menunjukkan bahwa Grad-CAM mampu memberikan visualisasi area citra yang berkontribusi terhadap prediksi model, sehingga meningkatkan transparansi sistem. Meskipun demikian, penelitian ini masih berfokus pada kategorisasi kanker paru secara umum dan tidak secara spesifik mengevaluasi kestabilan pelatihan model maupun generalisasi performa menggunakan strategi validasi silang yang komprehensif.

Sementara itu, Tasmim mengusulkan model Lightweight-CNN untuk deteksi kanker paru yang efisien secara komputasi, serta memanfaatkan Grad-CAM sebagai metode visualisasi. Pendekatan ini menekankan efisiensi model dan kecepatan inferensi, namun penggunaan arsitektur CNN yang relatif dangkal berpotensi membatasi kemampuan model dalam mengekstraksi fitur mikro yang kompleks, khususnya pada citra medis dengan detail morfologi tinggi.

Berdasarkan tinjauan terhadap penelitian-penelitian tersebut, dapat disimpulkan bahwa sebagian besar studi sebelumnya berfokus pada peningkatan performa klasifikasi atau efisiensi model, baik pada citra CT maupun citra medis lainnya. Namun, masih terbatas penelitian yang secara khusus mengkaji klasifikasi citra histopatologi kanker paru-paru menggunakan arsitektur CNN yang dalam dan stabil, sekaligus mengintegrasikan metode interpretabilitas untuk mendukung transparansi keputusan model. Oleh karena itu, penelitian ini memposisikan diri dengan mengombinasikan ResNet50 sebagai arsitektur CNN yang reliabel dan Grad-CAM sebagai metode interpretabilitas, guna menghasilkan sistem pendukung diagnosis yang tidak hanya akurat, tetapi juga dapat dipahami secara klinis.

3. METODE PENELITIAN


Berikut merupakan tahapan-tahapan dari penelitian ini yang telah dirangkum pada gambar 4.



Gambar 4. Tahapan Penelitian

3.1. Dataset

Penelitian menggunakan dataset LC25000, yang terdiri dari 15.000 citra histopatologi paru dengan tiga kelas berukuran seimbang. Pada gambar 5 di bawah ini merupakan contoh citra yang akan dipakai dalam penelitian ini, dari a.lung_adenocarcinoma, b. lung_squamous cell carcinoma, dan terakhir c. lung_normal.



Gambar 5 Dataset LC25000

Setiap kelas terdiri dari 5.000 citra berformat RGB 768×768 piksel. Dataset dibagi menjadi 80% data pelatihan dan 20% data uji. Data pelatihan juga digunakan untuk 5-Fold Cross Validation untuk mengurangi bias dan meningkatkan estimasi performa model.

3.2. Preprocessing

Tahapan preprocessing :

- Resize citra ke 224×224 piksel.
- Normalisasi intensitas piksel 0–1.
- Augmentasi: rotasi, width/height shift, zoom, shear, dan horizontal flip.
- Stratified split untuk menjaga keseimbangan tiap kelas[9].

3.3. Arsitektur ResNet50

- Model menggunakan pretrained ResNet50 dengan fine-tuning;
- Optimizer: Adam
- Learning rate awal: 0.0001
- Loss: categorical crossentropy
- Batch size: 32
- Epoch: 50 (early stopping on validation loss)
- Penambahan fully-connected layer 512 neuron + dropout 0.5 + softmax 3 kelas [10]

3.4. Evaluasi Model

Performa dievaluasi menggunakan:


- Accuracy
- Precision
- Recall
- F1-score
- Confusion matrix

Interpretasi dilakukan menggunakan Grad-CAM untuk memvisualisasikan fokus model pada masing-masing kelas [11].

4. HASIL DAN PEMBAHASAN

4.1. Kurva Pelatihan


Pelatihan model ResNet50 menunjukkan pola yang sangat stabil. Pada epoch-epoch awal, akurasi training meningkat tajam dari sekitar 0.65 menuju 0.90. Setelah itu, kurva memasuki fase stabilisasi dan bergerak menuju plateau di angka 0.96–0.97 pada epoch ke-30 hingga akhir. Sementara itu, akurasi validation juga meningkat signifikan sejak epoch pertama, bergerak dari 0.88 hingga mencapai nilai stabil di kisaran 0.96 mulai epoch ke-10 yang bisa dilihat pada gambar 6 di bawah.



Gambar 6. Kurva Akurasi

Pola ini menunjukkan bahwa model dapat mempelajari fitur penting dengan cepat dan tetap mempertahankan generalisasi yang baik pada data validation.

Dari sisi loss, terdapat penurunan drastis pada training loss dari 0.80 menjadi sekitar 0.10 dalam 10 epoch pertama yang bisa dilihat pada gambar 7 di bawah.




Gambar 7. Kurva Loss

Validation loss juga menunjukkan penurunan yang proporsional dan mencapai nilai stabil di kisaran 0.09–0.12. Tidak ada gap besar antara training loss dan validation loss, yang menunjukkan model tidak mengalami overfitting. Hal ini diperkuat oleh bentuk grafik validation loss yang hampir sejajar dengan training loss setelah epoch ke-12.

4.2. Evaluasi Restnet50 pada Data Testing

Evaluasi dilakukan menggunakan 1.499 citra pada folder test. Berdasarkan output model dan confusion matrix pada gambar 8, ResNet50 menunjukkan performa klasifikasi yang sangat baik. Nilai akurasi keseluruhan mencapai 0.9731, dengan nilai loss sebesar 0.1012, menandakan model mampu mengenali pola histopatologi secara akurat dan stabil.



Gambar 8. Confusion Matrix Restnet50

Berdasarkan confusion matrix, performa per kelas dapat dihitung sebagai berikut:

a. lung_aca (Adenocarcinoma)

- True Positive (TP): 470
- False Positive (FP): 13
- False Negative (FN): 30

(1 ke normal + 29 ke scc)

$$\text{Precision} = 470 / (470 + 13) = 0.9731$$

$$\text{Recall} = 470 / (470 + 30) = 0.9400$$

$$\text{F1-score} = 0.9563$$

b. lung_n (Normal)

- True Positive (TP): 500
- False Positive (FP): 1
- False Negative (FN): 0

$$\text{Precision} = 500 / (500 + 1) = 0.9980$$

$$\text{Recall} = 500 / (500 + 0) = 1.0000$$

$$\text{F1-score} = 0.9990$$

c. lung_scc (Squamous Cell Carcinoma)

- True Positive (TP): 486
- False Positive (FP): 29
- False Negative (FN): 13

$$\text{Precision} = 486 / (486 + 29) = 0.9437$$

$$\text{Recall} = 486 / (486 + 13) = 0.9739$$

$$\text{F1-score} = 0.9585$$

Hasil di atas menunjukkan bahwa kelas normal diklasifikasikan sempurna, sementara kesalahan terbesar terjadi pada pertukaran adenocarcinoma ↔ squamous cell carcinoma, yang secara klinis memang memiliki kemiripan morfologi.


4.3. Evaluasi Grad-CAM Restnet50

Untuk memahami mekanisme pengambilan keputusan model, dilakukan visualisasi Grad-CAM pada layer konvolusi terakhir ResNet50. Teknik ini menghasilkan peta aktivasi (heatmap) yang menunjukkan area mana dalam citra histopatologi yang memberikan kontribusi paling besar terhadap prediksi model. Analisis interpretabilitas ini krusial karena memastikan bahwa model tidak hanya menghafal pola permukaan, tetapi benar-benar belajar struktur morfologi penting yang relevan secara biologis.

Visualisasi Grad-CAM yang dihasilkan pada data uji menunjukkan pola aktivasi yang konsisten dengan karakteristik morfologi masing-masing kelas. Tiga contoh representatif dari tiap kelas (Squamous Cell Carcinoma, Adenocarcinoma, dan Normal) dianalisis sebagai berikut.

4.4. Squamous Cell Carcinoma (lung_scc)

Aktivasi Grad-CAM berpusat pada area sel-sel besar dengan nukleus hiper-kromatik dan struktur padat khas SCC yang bisa terlihat pada gambar 9. di bawah ini




Gambar 9. Grad-CAM pada lung_scc

Warna intens (kuning-merah) terkonsentrasi pada kelompok sel dengan pola keratinisasi dan intercellular bridges, yang merupakan ciri diagnostik utama karsinoma skuamosa. Temuan ini menunjukkan bahwa ResNet50 berhasil mengenali fitur patologis yang benar, bukan bagian citra yang tidak relevan seperti background atau artefak preparasi.

4.5. Adenocarcinoma (lung_aca)

Pada kelas adenokarsinoma, heatmap menunjukkan konsentrasi aktivasi pada pola glandular/pseudo-glandular, yaitu area yang membentuk lumen atau acinar-like structures yang terlihat pada gambar 10.



Gambar 10 Grad-CAM pada lung_aca

Warna biru-kuning-merah pada Grad-CAM mengindikasikan bahwa model memberikan bobot tinggi pada formasi kelenjar dan susunan epitel yang tidak beraturan—yang memang menjadi indikator patologi adenokarsinoma paru. Model tidak hanya fokus pada tepi jaringan atau noise, tetapi menyoroti struktur histologi kelenjar, artinya representasi fitur sangat selaras dengan literatur patologi.

4.6. Jaringan Normal (lung_n)

Visualisasi pada kelas normal memperlihatkan aktivasi yang rendah dan tidak terfokus. Heatmap cenderung berwarna biru lembut tanpa hotspot signifikan. Ini mencerminkan bahwa model tidak menemukan fitur patologis, sehingga tidak memberikan respons aktivasi kuat. Pola ini konsisten dan penting sebagai bukti bahwa ResNet50 tidak menghasilkan false-positive berlebihan pada jaringan sehat.

5. KESIMPULAN DAN SARAN

Penelitian ini membuktikan bahwa ResNet50 merupakan arsitektur CNN yang efektif, stabil, dan reliabel dalam melakukan klasifikasi citra histopatologi kanker paru-paru dari dataset LC25000. Hasil pengujian menunjukkan akurasi tinggi sebesar 0.9731, dengan nilai precision, recall, dan F1-score yang konsisten kuat pada ketiga kelas yang diuji. Performa ini menunjukkan bahwa ResNet50 mampu mengekstraksi fitur-fitur mikroskopis yang kompleks—seperti variasi struktur glandular, pleomorfisme inti sel, serta pola keratinisasi—yang menjadi penanda penting pada adenocarcinoma dan squamous cell carcinoma. Selain itu, stabilitas kurva training dan validation mengindikasikan bahwa pipeline preprocessing (resize, normalisasi, augmentasi), pembagian data stratifikatif, dan penggunaan 5-Fold Cross Validation berhasil meminimalkan risiko overfitting.

Integrasi Grad-CAM juga memberikan kontribusi signifikan terhadap interpretabilitas model. Visualisasi heatmap berhasil menyoroti area patologis yang relevan, seperti kepadatan nukleus abnormal pada adenocarcinoma dan area keratinisasi pada squamous cell carcinoma. Hal ini memperkuat bahwa model tidak hanya mencapai akurasi tinggi, tetapi juga mengambil keputusan berdasarkan informasi visual yang bermakna secara klinis. Dengan demikian, kombinasi ResNet50 dan Grad-CAM dapat diusulkan sebagai solusi awal sistem pendukung diagnosis (CAD) untuk membantu patolog dalam proses penilaian citra histopatologi paru secara lebih cepat, konsisten, dan transparan.

Sebagai pengembangan selanjutnya, penelitian ini disarankan untuk menggunakan dataset lokal atau data klinis dari rumah sakit di Indonesia agar model memiliki relevansi klinis yang lebih kuat dan mampu merepresentasikan variasi nyata dalam metode pewarnaan, kualitas slide, serta kondisi preparat jaringan, mengingat dataset publik seperti LC25000

cenderung bersifat bersih dan seragam. Selain itu, model ResNet50 yang telah dikembangkan dapat diintegrasikan ke dalam sistem pendukung diagnosis (CAD) berbasis web atau aplikasi klinis, sehingga patolog dapat memperoleh hasil prediksi dan visualisasi interpretasi Grad-CAM secara langsung dalam alur kerja diagnosis. Evaluasi lebih lanjut juga perlu dilakukan terhadap citra histopatologi dengan kualitas rendah atau mengandung noise, seperti blur dan variasi intensitas pewarnaan, untuk menilai robustness model pada kondisi dunia nyata, termasuk melalui penerapan teknik augmentasi lanjutan seperti stain normalization. Mengingat kompleksitas komputasi ResNet50 yang relatif tinggi, perbandingan dengan arsitektur CNN yang lebih ringan, seperti MobileNetV2 atau EfficientNet-B0, penting dilakukan guna memperoleh keseimbangan optimal antara akurasi dan efisiensi untuk kebutuhan deployment di fasilitas kesehatan dengan sumber daya terbatas. Terakhir, penambahan metode interpretabilitas lain selain Grad-CAM, seperti LayerCAM, Score-CAM, atau Grad-CAM++, dapat dipertimbangkan untuk menghasilkan visualisasi yang lebih kaya dan presisi, sehingga meningkatkan kepercayaan terhadap keputusan model.

DAFTAR PUSTAKA

- [1] World Health Organization, "Lung Cancer," <https://www.who.int/news-room/fact-sheets/detail/cancer>.
- [2] Y. Huang *et al.*, "A novel approach to integrating Vision Transformers and machine learning for robust lung nodule classification using CT imaging," *J. Radiat. Res. Appl. Sci.*, vol. 18, no. 3, p. 101672, Sep. 2025, doi: 10.1016/j.jrras.2025.101672.
- [3] R. Mothkur, P. Soubhagyalakshmi, and C. B. Swetha, "Grad-CAM Based Visualization for Interpretable Lung Cancer Categorization Using Deep CNN Models," *J. Electron. Electromed. Eng. Med. Informatics*, vol. 7, no. 3, pp. 567–580, Jul. 2025, doi: 10.35882/jeeemi.v7i3.690.
- [4] Tasmim *et al.*, "A Lightweight-CNN Model for Efficient Lung Cancer Detection and Grad-CAM Visualization," in *2023 International Conference on Information and Communication Technology for Sustainable Development, ICICT4SD 2023 - Proceedings*, Institute of Electrical and Electronics Engineers Inc., 2023, pp. 254–258. doi: 10.1109/ICICT4SD59951.2023.10303569.
- [5] A. A. Borkowski, M. M. Bui, L. Brannon Thomas, C. P. Wilson, L. A. Deland, and S. M. Mastorides, "Lung and Colon Cancer Histopathological Image Dataset (LC25000)." [Online]. Available: <https://github.com/beamandrew/medical-data>
- [6] A. Chaddad, J. Peng, and Y. Wu, "Classification based deep learning models for lung cancer and disease using medical images," Jul. 2025, doi: 10.1109/TRPMS.2025.3584031.

- [7] G. Inbasakaran and J. Anitha Ruth, "Clinical-ready CNN framework for lung cancer classification: Systematic optimization for healthcare deployment with enhanced computational efficiency," *Intell. Med.*, vol. 12, Jan. 2025, doi: 10.1016/j.ibmed.2025.100292.
- [8] R. R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh, and D. Batra, "Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization." [Online]. Available: <http://gradcam.cloudcv.org>
- [9] A. N. Mir, D. R. Rizvi, and M. R. Ahmad, "Enhancing histopathological image analysis: An explainable vision transformer approach with comprehensive interpretation methods and evaluation of explanation quality," *Eng. Appl. Artif. Intell.*, vol. 149, Jun. 2025, doi: 10.1016/j.engappai.2025.110519.
- [10] E. Matsuyama, H. Watanabe, and N. Takahashi, "Performance Comparison of Vision Transformer- and CNN-Based Image Classification Using Cross Entropy: A Preliminary Application to Lung Cancer Discrimination from CT Images," *J. Biomed. Sci. Eng.*, vol. 17, no. 09, pp. 157–170, 2024, doi: 10.4236/jbise.2024.179012.
- [11] Komal Patil, Neesha Dholakiya, Divya Padhiyar, Bhasha Anjaria, and Khushbu Rana, "A Hybrid Explainable AI Framework for Early Lung Cancer Detection Using CTGAN-Augmented Clinical Data, Gene Biomarkers, and Transformer-CNN Networks," *Metall. Mater. Eng.*, vol. 31, no. 4, pp. 373–379, Apr. 2025, doi: 10.63278/1446.