

PENERAPAN ALGORITMA MACHINE LEARNING DALAM DETEKSI KANKER MELALUI RADIOGRAFI : PENDEKATAN SYSTEMATIC LITERATURE REVIEW

Faisal Rizki Bachtiar *¹

¹Program Studi Ilmu Radiologi, Universitas Brawijaya

*e-mail: rizkifaisal81@gmail.com¹

Abstrak

Deteksi dini kanker merupakan kunci untuk meningkatkan peluang kesembuhan pasien, namun interpretasi radiografi secara manual masih menghadapi kendala seperti keterbatasan tenaga medis dan subjektivitas diagnosis. Seiring berkembangnya kecerdasan buatan, algoritma machine learning (ML) menjadi solusi potensial dalam meningkatkan akurasi dan efisiensi deteksi kanker berbasis citra radiografi seperti X-ray, CT scan, dan MRI. Penelitian ini bertujuan untuk menyusun pemetaan sistematis terkait implementasi algoritma ML dalam deteksi kanker berbasis radiografi melalui pendekatan Systematic Literature Review (SLR). Dengan mengacu pada protokol PRISMA, penelusuran dilakukan terhadap 100 artikel yang kemudian diseleksi menjadi 30 artikel relevan dari rentang tahun 2020–2025. Hasil kajian menunjukkan bahwa algoritma CNN dan turunannya (VGG, ResNet, EfficientNet) mendominasi implementasi dengan akurasi tinggi, terutama pada kanker paru-paru dan payudara. Tantangan utama yang teridentifikasi meliputi keterbatasan data, interpretabilitas model yang rendah, hingga generalisasi yang lemah di luar data pelatihan. Sebagai respons, berbagai solusi telah dikembangkan, termasuk augmentasi data berbasis GAN, integrasi multimodal data, serta penerapan teknik Explainable AI untuk meningkatkan transparansi model. Studi ini menegaskan pentingnya pendekatan berbasis integrasi teknologi dan konteks klinis untuk mengakselerasi adopsi ML dalam sistem diagnostik kanker yang lebih andal dan manusiawi.

Kata kunci: Machine Learning, Deteksi Kanker, Radiografi, Systematic Literature Review, Deep Learning

Abstract

Early cancer detection is key to improving patient survival rates; however, manual interpretation of radiographic images still faces challenges such as limited medical personnel and diagnostic subjectivity. With the advancement of artificial intelligence, machine learning (ML) algorithms have emerged as a potential solution to enhance the accuracy and efficiency of cancer detection using radiographic images such as X-rays, CT scans, and MRIs. This study aims to systematically map the implementation of ML algorithms in radiographic-based cancer detection through a Systematic Literature Review (SLR) approach. Following the PRISMA protocol, an initial screening of 100 articles was conducted, resulting in 30 relevant articles published between 2020 and 2025. The findings reveal that convolutional neural networks (CNNs) and their derivatives (e.g., VGG, ResNet, EfficientNet) dominate implementations, showing high accuracy, particularly in lung and breast cancer detection. Key challenges identified include limited datasets, low model interpretability, and poor generalization to unseen data. In response, several solutions have been proposed, including GAN-based data augmentation, multimodal data integration, and the use of Explainable AI techniques to improve model transparency. This study highlights the importance of integrating technology and clinical context to accelerate the adoption of ML in developing more reliable and human-centered cancer diagnostic systems.

Keywords: Machine Learning, Cancer Detection, Radiography, Systematic Literature Review, Deep Learning

PENDAHULUAN

Kanker tetap menjadi salah satu beban kesehatan paling signifikan secara global, dengan sekitar 20 juta kasus baru dan hampir 10 juta kematian tercatat pada tahun 2022 (World Health Organization, 2022). Dalam upaya mengurangi angka kematian akibat kanker, deteksi dini menjadi aspek yang sangat krusial. Teknik radiografi seperti sinar-X, computed tomography (CT), dan magnetic resonance imaging (MRI) telah lama digunakan sebagai alat utama dalam proses deteksi dini tersebut. Namun, interpretasi radiografi secara konvensional masih mengandalkan keahlian radiolog manusia, yang rentan terhadap variabilitas subjektif, kelelahan, dan keterbatasan pengalaman klinis, terutama dalam kondisi sistem layanan kesehatan yang

terbebani oleh kekurangan tenaga spesialis (McBee et al., 2018). Oleh karena itu, integrasi teknologi seperti machine learning (ML) menjadi penting sebagai pendekatan inovatif yang dapat meningkatkan akurasi, efisiensi, dan konsistensi dalam mendeteksi kanker melalui citra radiografi.

Machine learning, khususnya deep learning dengan arsitektur convolutional neural networks (CNN), telah menunjukkan potensi besar dalam klasifikasi citra medis dan segmentasi lesi kanker. Algoritma seperti ResNet, VGG, DenseNet, dan U-Net digunakan dalam berbagai studi untuk mendeteksi kanker payudara, paru-paru, otak, dan prostat melalui radiografi dengan akurasi yang mendekati atau bahkan melampaui performa dokter spesialis (Litjens et al., 2017). Namun, keanekaragaman pendekatan dan ketidakkonsistenan dalam pelaporan hasil membuat sulit untuk merumuskan standar yang dapat digunakan secara klinis. Beberapa studi menunjukkan bahwa sensitivitas dan spesifisitas model sangat bergantung pada kualitas data, preprocessing, dan arsitektur model yang digunakan, yang menimbulkan tantangan besar dalam hal replikasi dan validasi eksternal (Rajpurkar et al., 2018).

Permasalahan lain yang muncul adalah keterbatasan ketersediaan data medis berkualitas tinggi yang telah teranotasi dengan baik. Citra radiografi sering kali memiliki ketidakseimbangan kelas (class imbalance), noise, dan kompleksitas anatomis yang tinggi, yang menyulitkan pelatihan model ML. Selain itu, isu privasi data dan regulasi etika juga membatasi akses ke dataset besar yang diperlukan untuk pelatihan model yang generalizable (Miotto et al., 2017). Selain keterbatasan teknis, adopsi ML dalam praktik klinis juga terkendala oleh sifat “black-box” algoritma deep learning, di mana proses pengambilan keputusan sulit diinterpretasikan oleh dokter. Ketiadaan transparansi ini menyebabkan rendahnya kepercayaan pengguna klinis terhadap model-model otomatis tersebut, sehingga memperlambat penerapannya dalam sistem pelayanan kesehatan nyata (Tjoa & Guan, 2020).

Lebih jauh lagi, sebagian besar studi yang meneliti penerapan ML dalam deteksi kanker melalui radiografi bersifat eksperimental atau berbasis data lokal, tanpa mempertimbangkan faktor-faktor kontekstual yang mempengaruhi implementasi secara luas, seperti keterbatasan sumber daya rumah sakit, kesiapan infrastruktur digital, dan kompetensi tenaga medis. Belum adanya pemetaan sistematis terhadap algoritma yang digunakan, performa masing-masing model dalam konteks penyakit spesifik, serta kendala implementasi aktual menunjukkan adanya gap dalam literatur yang perlu diisi. Dengan demikian, pendekatan Systematic Literature Review (SLR) menjadi penting untuk menyintesis pengetahuan yang tersebar dari berbagai studi, sekaligus memberikan pemahaman komprehensif terhadap perkembangan, tantangan, dan solusi dalam penerapan ML untuk deteksi kanker melalui radiografi (Page et al., 2021).

Oleh karena itu, penelitian ini bertujuan untuk menyusun pemetaan sistematis terhadap literatur yang relevan guna menjawab tiga pertanyaan utama: jenis algoritma ML yang digunakan, performa algoritma berdasarkan metrik evaluasi radiografi, serta tantangan dan solusi implementasinya. Dengan pendekatan ini, penelitian diharapkan dapat memberikan kontribusi terhadap pengembangan kerangka kerja penerapan ML dalam bidang onkologi radiologi secara lebih praktis dan kontekstual, sekaligus mendorong integrasi teknologi cerdas ke dalam ekosistem layanan kesehatan yang berkeadilan dan efisien.

METODE

Penelitian ini menggunakan metode Systematic Literature Review (SLR) untuk mengidentifikasi, menelaah, dan mensintesis literatur ilmiah terkait penerapan algoritma *machine learning* dalam deteksi kanker melalui citra radiografi. Proses peninjauan dilakukan secara sistematis berdasarkan pedoman Preferred Reporting Items for Systematic Reviews and

Meta-Analyses (PRISMA) (Page et al., 2021), yang mencakup empat tahap utama: identifikasi, penyaringan, uji kelayakan, dan inklusi.

Langkah awal dalam pelaksanaan SLR dimulai dengan perumusan tujuan dan pertanyaan penelitian, yang kemudian menjadi dasar untuk menyusun strategi pencarian literatur. Kata kunci yang digunakan dalam proses pencarian adalah: “*machine learning*”, “*cancer detection*”, “*radiography*”, “*medical imaging*”, dan dikombinasikan dengan operator Boolean untuk memaksimalkan hasil pencarian. Proses pencarian dilakukan pada tiga basis data ilmiah utama, yaitu Google Scholar, ScienceDirect, dan Wiley Online Library.

Beberapa batasan (filter) ditetapkan untuk memastikan kualitas dan relevansi data, yaitu:

- Jenis dokumen: artikel jurnal ilmiah dan literature review,
- Periode publikasi: tahun 2020–2025,
- Bahasa: Inggris,
- Fokus kajian: penerapan machine learning pada deteksi kanker melalui radiografi (seperti X-ray, CT scan, dan MRI).

Seluruh artikel yang diperoleh diunduh dan disimpan menggunakan aplikasi referensi Mendeley, lalu diekstraksi dan dicatat secara manual ke dalam lembar kerja untuk dianalisis lebih lanjut. Tahap penyaringan dilakukan dengan membaca judul dan abstrak untuk mengeliminasi artikel yang tidak relevan. Selanjutnya, dilakukan telaah isi penuh terhadap artikel yang memenuhi syarat awal.

Kriteria inklusi meliputi:

- Artikel membahas implementasi algoritma machine learning dalam deteksi kanker berbasis radiografi,
- Artikel dipublikasikan dalam jurnal peer-reviewed pada kurun waktu 2020–2025,
- Artikel tersedia dalam teks lengkap dan berbahasa Inggris.


Kriteria eksklusi mencakup:

- Artikel berupa editorial, abstrak konferensi, atau tidak tersedia full-text,
- Artikel yang hanya membahas klasifikasi citra medis tanpa keterkaitan eksplisit dengan deteksi kanker.

Artikel yang lolos seleksi akhir dianalisis untuk mengidentifikasi algoritma yang digunakan, jenis kanker yang diteliti, jenis radiografi yang diaplikasikan, serta keunggulan dan tantangan implementasinya. Proses ini menghasilkan sintesis tematik yang menjadi dasar pembahasan hasil SLR secara menyeluruh. Data yang dikumpulkan akan dievaluasi menggunakan pertanyaan penilaian kualitas berikut:

- a. Apakah artikel tersebut diterbitkan dalam jurnal ilmiah yang terindeks di Google Scholar, ScienceDirect, atau Wiley Online Library pada rentang tahun 2020 hingga 2025?
- b. Apakah artikel secara eksplisit membahas penerapan algoritma *machine learning* dalam proses deteksi kanker menggunakan citra radiografi (seperti X-ray, CT scan, atau MRI)?

Jika jawaban dari kedua pertanyaan di atas adalah “ya”, maka artikel dianggap **layak** dan akan disertakan dalam proses sintesis data SLR.



Gambar 1. Alur Diagram PRISMA

Proses tinjauan sistematis dalam studi ini mengikuti alur PRISMA yang mencakup empat tahapan utama: identifikasi, penyaringan, uji kelayakan, dan inklusi. Pada tahap identifikasi, peneliti menetapkan tujuan studi serta merancang protokol tinjauan, lalu melakukan pencarian literatur secara sistematis pada database Google Scholar, ScienceDirect, dan Wiley Online Library dengan batasan tahun terbit 2020–2025. Dari proses ini diperoleh 100 artikel awal. Tahap penyaringan dilakukan dengan menerapkan kriteria eksklusi berdasarkan topik, jenis dokumen, dan kesesuaian dengan fokus penelitian, sehingga 65 artikel dieliminasi. Selanjutnya, tahap kelayakan dilakukan dengan mengevaluasi isi penuh artikel untuk memastikan kedalaman pembahasan terkait penerapan algoritma *machine learning* dalam deteksi kanker melalui radiografi. Pada akhirnya, 30 artikel memenuhi seluruh kriteria inklusi dan dianalisis lebih lanjut.

Sintesis data dilakukan secara naratif-tematik untuk menjawab pertanyaan penelitian terkait praktik algoritma *machine learning*, jenis kanker yang diteliti, serta efektivitas model pada citra radiografi seperti X-ray, CT scan, dan MRI. Kajian ini mengelompokkan artikel berdasarkan jenis algoritma yang digunakan (misalnya CNN, SVM, VGGNet), jenis kanker (paru, payudara, prostat, dan lain-lain), serta tantangan implementasi seperti keterbatasan data dan akurasi sistem. Pendekatan ini menghasilkan pemetaan sistematis terhadap perkembangan riset dalam lima tahun terakhir serta menyoroti area yang masih kurang dieksplorasi sebagai celah penelitian selanjutnya.

HASIL DAN PEMBAHASAN

Tren Penelitian Terkait Penerapan Algoritma Machine Learning Dalam Deteksi Kanker Melalui Radiografi

Dalam analisis literatur sistematis ini, tren publikasi menunjukkan adanya peningkatan signifikan dalam jumlah penelitian terkait penerapan algoritma machine learning (ML) untuk

deteksi kanker berbasis radiografi dalam lima tahun terakhir. Tabel 1 menampilkan distribusi temporal artikel dari tahun 2021 hingga 2025, yang mencerminkan percepatan penelitian seiring meningkatnya kebutuhan solusi diagnostik berbasis kecerdasan buatan dalam bidang radiologi onkologi.

Tabel 1. Frekuensi Artikel Berdasarkan Tahun Terbit

Tahun Terbit	Frekuensi	Persentase (%)	Sitasi
2021	1	3.33%	Kumar & Alqahtani (2021)
2022	1	3.33%	Malibari et al. (2022)
2023	3	10.00%	Sreeprada & Vedavathi (2023), Gawade et al. (2023), Asadi & Memon (2023) Hammad et al. (2024), Elhassan et al. (2024), Angel mary & Thanammal (2024), Zhang & Lee (2024), Kavitha et al. (2024), Kumar et al. (2024), Crasta et al. (2024), Fransen et al. (2024), Mishra et al. (2024), Aarthiy et al. (2024)
2024	10	33.33%	Taguelmimt et al. (2025), Yan et al. (2025), Sharma et al. (2025), Choudhury et al. (2025), Ansari et al. (2025), Kumar et al. (2025), Lokaj et al. (2025), Dharani & Danesh (2025), Thapa & Kaur (2025), Dana et al. (2025), Reschke et al. (2025), Nobel et al. (2025), Mesropyan et al. (2025), Nguyen-Tat et al. (2025), Shatnawi et al. (2025)
2025	15	50.00%	
Total	30	100%	

Pada tahun 2025 menjadi titik puncak dengan kontribusi setengah dari total artikel (15 artikel atau 50%). Ini menunjukkan bahwa isu ini bukan hanya tren sesaat, melainkan telah menjadi perhatian utama dalam dunia penelitian kesehatan digital. Tahun 2024 juga menunjukkan produktivitas tinggi dengan 10 artikel (33,33%), sedangkan sebelum 2023, hanya sedikit studi yang muncul, masing-masing hanya satu hingga tiga artikel. Hal ini dapat dimaknai sebagai masa pengenalan teknologi machine learning dalam radiologi, yang kemudian berkembang pesat seiring kemajuan kecerdasan buatan dan meningkatnya kebutuhan akan sistem diagnostik yang lebih cepat dan akurat.

Kecenderungan ini juga bisa dilihat sebagai cerminan dari kondisi dunia kesehatan pasca-pandemi, di mana efisiensi dan otomatisasi menjadi semakin penting. Para peneliti tampak semakin terpenggil untuk mengeksplorasi potensi AI tidak hanya sebagai alat bantu teknis, tetapi juga sebagai bagian dari sistem pendukung keputusan klinis yang lebih manusiawi—memberikan dokter alat yang bisa membantu menganalisis lebih cepat, namun tetap transparan dan dapat dipercaya.

Implementasi Algoritma Machine Learning Dalam Deteksi Kanker Melalui Radiografi

Penerapan algoritma machine learning dalam deteksi kanker melalui radiografi menunjukkan perkembangan yang pesat dalam berbagai jenis kanker dan pendekatan teknologinya. Literatur terkini memperlihatkan keberagaman model dan arsitektur yang diimplementasikan, mulai dari Convolutional Neural Network (CNN) hingga model hybrid dan transformer canggih, yang disesuaikan dengan karakteristik citra dan jenis kanker yang dianalisis. Untuk memahami lanskap implementasi tersebut secara menyeluruh, Tabel 2 berikut merangkum jenis kanker, algoritma yang digunakan, serta capaian performa model berdasarkan studi-studi yang telah direview.

Tabel 2. Rangkuman Penggunaan Algoritma Machine Learning dalam Mendeteksi Kanker Berbasis Radiografi

Jenis Kanker	Jenis Algoritma Machine Learning	Model Performa	Sitasi
Campuran (Histopatologi)	CancerNet (CNN, Involution, Transformer)	Akurasi 97.4%	Nobel et al. (2025)
Campuran (Payudara, Otak, Kulit, Prostat)	CNN, General DL Overview	Akurasi 92.0%	Kumar & Alqahtani (2021)
Campuran (Sel kanker)	Advanced ML for Cell Detection	Akurasi 96.0%	Mishra et al. (2024)
Campuran (X-ray, MRI, USG)	MobileNetV2, EfficientNet-B4, DenseNet	Akurasi 93.0%	Nguyen-Tat et al. (2025)
Kulit	CNN, R-CNN	Akurasi 93.6%	Kavitha et al. (2024)
Oral	EfficientNet-B5 + ResNet50V2 + TSA	Akurasi 95.5%	Dharani & Danesh (2025)
	CNN, TPOT Genetic Optimization	Akurasi 96.1%	Hammad et al. (2024)
	Hybrid CNN-SVM (OCNN-SVM)	Akurasi 93.7%	Sreeprada & Vedavathi (2023)
	CNN, Transfer Learning (VGG16, ResNet50, InceptionV3)	Akurasi 94.1%	Choudhury et al. (2025)
	SVM + VGGNet-16	Akurasi 97.3%	Ansari et al. (2025)
	CNN + YOLOv8 + DCGAN	Akurasi 96.9%	Elhassan et al. (2024)
	CNN + Explainability (Grad-CAM, LIME, DeepLIFT)	Akurasi 91.3%	Thapa & Kaur (2025)
Paru-paru	Pyramid Network + Honey Badger Algorithm	Akurasi 93.8%	Angel Mary & Thanammal (2024)
	CNN, KNN, VGG16, RNN	Akurasi 95.1%	Kumar et al. (2024)
	3D-VNet + 3D-ResNet	Akurasi 96.2%	Crasta et al. (2024)
	Enhanced CNN (ConvNeXtSmall, VGG16, EfficientNetB0)	Akurasi 96.7%	Shatnawi et al. (2025)
	VGG16 + Random Forest/XGBoost, GLCM, LightGBM	Akurasi 92.3%	Sharma et al. (2025)

Payudara	Multi-Autoencoder, XGBoost, Attention	Akurasi 94.8%, AUC 0.98	Yan et al. (2025)
	CAMR-Gabor Filter + LSTM	Akurasi 91.7%, Sensitivitas 92.6%	Kumar et al. (2025)
	Transformer (MMST-V), Vision Transformer	AUC 0.976, Akurasi 94.6%	Lokaj et al. (2025)
	UNet + ResNet50	Akurasi 94.3%	Asadi & Memon (2023)
	Adaptive-CS-Net + Precise-Image-Net	Akurasi 94.8%	Mesropyan et al. (2025)
	CNN + DBN + Butterfly Optimization	Akurasi 92.9%	Malibari et al. (2022)
	Deep Learning (DL), Bimodal CNN	Akurasi 95.2%	Taguelmimt et al. (2025)
Prostat	Deep Learning Reconstruction	AUC 0.92	Dana et al. (2025)
	DL-enhanced MRI with P4	Akurasi 93.4%	Reschke et al. (2025)
	Deep Learning Protocol Evaluation	Akurasi 91.8%	Fransen et al. (2024)
Tiroid	CNN + CAD System	Akurasi 94.5%	Zhang & Lee (2024)
Tulang	GCNN, RSCH, MSER	Akurasi 91.5%	Aarthy et al. (2024)
Tulang (Osteosarcoma)	CNN (ResNet101)	Akurasi 90.5%	Gawade et al. (2023)

Tabel 2 memperlihatkan keberagaman jenis kanker, algoritma yang digunakan, serta capaian performa model yang telah dikembangkan dalam literatur. Salah satu temuan yang menonjol adalah tingginya kepercayaan peneliti terhadap algoritma CNN (Convolutional Neural Network) dan turunannya, baik yang berdiri sendiri maupun dikombinasikan dengan model lain seperti SVM, LSTM, Transformer, hingga teknik ensemble. Ini bukan hal yang mengherankan, mengingat kemampuan CNN yang luar biasa dalam mengenali pola visual dari citra medis yang kompleks. Pada kanker paru-paru, misalnya, ditemukan lebih dari sepuluh pendekatan berbeda mulai dari model hybrid CNN-SVM, transfer learning dengan arsitektur VGG dan ResNet, hingga integrasi YOLOv8 untuk deteksi objek dan GAN untuk augmentasi data. Sebagian besar model tersebut mencatatkan akurasi di atas 95%, yang menunjukkan bahwa teknologi ini bukan sekadar eksperimen, melainkan benar-benar mendekati siap pakai dalam praktik klinis. Demikian pula pada kanker payudara, integrasi autoencoder, attention mechanism, dan segmentasi berbasis UNet menghasilkan AUC dan akurasi tinggi, mendekati 0.98 sebuah capaian yang sangat menjanjikan.

Tak kalah menarik, sejumlah studi juga berfokus pada jenis kanker yang lebih jarang disorot, seperti kanker tulang, tiroid, dan oral. Meskipun tantangannya lebih besar karena data yang lebih terbatas, pendekatan seperti generative deep belief networks dan optimasi dengan algoritma metaheuristik mampu menghasilkan performa yang kompetitif. Ini menunjukkan bahwa dengan pendekatan yang tepat dan data yang representatif, teknologi AI dapat membuka peluang baru dalam deteksi dini kanker, bahkan untuk kasus-kasus yang selama ini sulit didiagnosis secara akurat. Penelitian ini memberikan gambaran bahwa pemanfaatan machine learning dalam deteksi kanker melalui radiografi tidak hanya berkembang pesat secara teknis, tetapi juga mulai bergerak ke arah yang lebih inklusif dan aplikatif. Integrasi antara akurasi model,

interpretabilitas, dan kecepatan prediksi menjadi kunci dalam menjawab tantangan sistem kesehatan modern. Dengan pendekatan yang tepat, teknologi ini tidak hanya menjanjikan efisiensi, tetapi juga dapat membawa dimensi kemanusiaan yang lebih kuat dalam layanan medis berbasis teknologi.

Tantangan dan Solusi Implementasi Machine Learning Dalam Deteksi Kanker Berbasis Radiografi

Meskipun algoritma machine learning menawarkan potensi besar dalam meningkatkan akurasi dan efisiensi deteksi kanker berbasis radiografi, implementasinya di lapangan masih menghadapi berbagai tantangan teknis dan klinis yang kompleks. Berbagai studi telah mengidentifikasi hambatan mulai dari keterbatasan data medis hingga rendahnya interpretabilitas model. Namun demikian, seiring dengan perkembangan teknologi dan metodologi, para peneliti juga mulai menawarkan solusi strategis yang bertujuan untuk mengatasi kendala-kendala tersebut. Tabel 3 berikut merangkum tantangan utama beserta solusi yang diusulkan dalam literatur terkini guna meningkatkan efektivitas dan kesiapan klinis algoritma ML dalam deteksi kanker.

Tabel 3. Tantangan dan Solusi Implementasi Machine Learning Dalam Deteksi Kanker Berbasis Radiografi

No.	Tantangan/Solusi	Deskripsi	Sitasi
Tantangan			
1	Keterbatasan data medis berkualitas tinggi dan beranotasi	Banyak model gagal mencapai akurasi tinggi karena keterbatasan jumlah data yang berlabel dan variasi distribusi data.	Crasta et al. (2024); Elhassan et al. (2024); Sharma et al. (2025); Gawade et al. (2023); Zhang & Lee (2024); Choudhury et al. (2025); Aarthy et al. (2024); Mishra et al. (2024); Nguyen-Tat et al. (2025)
2	Kurangnya interpretabilitas model deep learning (black-box nature)	Kurangnya transparansi pada cara model membuat keputusan menghambat adopsi dalam praktik klinis.	Yan et al. (2025); Thapa & Kaur (2025); Nobel et al. (2025); Kumar & Alqahtani (2021); Taguelmimt et al. (2025)
3	Variabilitas data akibat perbedaan alat, pasien, dan teknik pencitraan	Perbedaan kualitas dan format gambar dari berbagai institusi menurunkan akurasi deteksi lintas domain.	Kumar et al. (2025); Dana et al. (2025); Lokaj et al. (2025); Fransen et al. (2024); Mesropyan et al. (2025); Reschke et al. (2025)
4	Overfitting dan generalisasi buruk pada dataset kecil	Model sering hanya bekerja optimal pada data pelatihan dan gagal ketika diterapkan ke data baru.	Angel mary & Thanammal (2024); Sreeprada & Vedavathi (2023); Ansari et al. (2025); Asadi & Memon (2023); Hammad et al. (2024)
5	Ketidakpastian hasil prediksi yang	Model ML tidak menunjukkan seberapa percaya diri terhadap hasil	Taguelmimt et al. (2025); Nobel et al. (2025); Yan et al.

	sulit dikalibrasi di praktik klinis	diagnosis, yang berisiko dalam pengambilan keputusan medis.	(2025); Sharma et al. (2025); Dharani & Danesh (2025)
Solusi Strategis			
1	Penggunaan data sintetis dan augmentasi berbasis GAN/transformer	Menggunakan metode seperti DCGAN dan augmentasi spektral untuk menghasilkan variasi data yang membantu pelatihan.	Elhassan et al. (2024); Angel mary & Thanammal (2024); Mesropyan et al. (2025); Nguyen-Tat et al. (2025); Crasta et al. (2024)
2	Integrasi multimodalitas (gambar dan data klinis) untuk akurasi lebih baik	Menggabungkan MRI/CT dengan data klinis seperti PSA, volume tumor, usia untuk prediksi lebih akurat dan andal.	Taguelmimt et al. (2025); Lokaj et al. (2025); Dana et al. (2025); Kumar et al. (2025); Nobel et al. (2025)
3	Penggunaan teknik explainable AI (XAI) seperti Grad-CAM dan LIME	Menggunakan visualisasi peta aktivasi untuk menjelaskan keputusan model kepada dokter dan pasien.	Thapa & Kaur (2025); Nobel et al. (2025); Yan et al. (2025); Kumar & Alqahtani (2021)
4	Penerapan ensemble dan transfer learning untuk generalisasi lebih kuat	Mengombinasikan CNN dengan model pretrained seperti ResNet, VGG, dan EfficientNet untuk meningkatkan akurasi dan efisiensi.	Choudhury et al. (2025); Ansari et al. (2025); Dharani & Danesh (2025); Hammad et al. (2024); Asadi & Memon (2023)
5	Optimasi hyperparameter dan seleksi fitur otomatis berbasis algoritma evolusioner	Menggunakan algoritma seperti TPOT, Swarm Optimization, dan XGBoost-RFE untuk memilih parameter terbaik secara otomatis.	Hammad et al. (2024); Dharani & Danesh (2025); Malibari et al. (2022); Aarth et al. (2024); Mishra et al. (2024)

Dalam implementasinya, algoritma machine learning (ML) untuk deteksi kanker berbasis radiografi menghadapi berbagai tantangan signifikan yang menghambat efektivitasnya dalam praktik klinis. Salah satu tantangan utama adalah keterbatasan data medis yang berkualitas tinggi dan beranotasi dengan baik. Banyak studi melaporkan bahwa model ML cenderung overfitting ketika dilatih pada dataset yang terbatas dan tidak representatif. Ketiadaan anotasi yang akurat serta distribusi data yang tidak merata menjadi penyebab utama kegagalan model dalam mencapai generalisasi yang baik. Hal ini diperparah oleh variabilitas data akibat perbedaan alat pencitraan, teknik pengambilan gambar, dan karakteristik pasien di berbagai institusi. Perbedaan ini berdampak langsung terhadap performa model lintas domain dan menjadi tantangan besar untuk penerapan model secara luas di berbagai fasilitas kesehatan.

Tantangan lain yang tak kalah penting adalah sifat "black-box" dari model deep learning yang menghambat transparansi dalam pengambilan keputusan medis. Dalam konteks deteksi kanker, dokter dan tenaga medis dituntut untuk memahami dasar dari keputusan diagnosis sebelum menyetujui atau menindaklanjutinya. Namun, sebagian besar model deep learning tidak memberikan penjelasan yang dapat dipahami oleh manusia atas prediksi yang dihasilkannya.

Kurangnya interpretabilitas ini membuat para profesional kesehatan cenderung skeptis dalam mengandalkan hasil dari sistem ML sepenuhnya, karena tidak disertai dengan argumen visual atau logika medis yang dapat divalidasi. Di sisi lain, ketidakpastian hasil prediksi model—yakni ketidakmampuan algoritma untuk menunjukkan tingkat kepercayaan pada hasilnya—juga menjadi isu serius, karena dalam praktik klinis, informasi mengenai tingkat kepastian sangat penting dalam pengambilan keputusan diagnostik dan terapeutik.

Menghadapi berbagai kendala tersebut, literatur merekomendasikan sejumlah solusi strategis berbasis pendekatan teknologi lanjut. Salah satu pendekatan yang paling banyak dikembangkan adalah penggunaan data sintesis dan augmentasi berbasis Generative Adversarial Network (GAN) maupun transformer, yang memungkinkan pengayaan dataset secara realistis dan variatif. Teknik ini membantu model belajar dari representasi yang lebih luas dan mencegah overfitting. Selain itu, pendekatan integratif yang menggabungkan data gambar dengan informasi klinis pasien (seperti usia, volume tumor, atau kadar PSA) terbukti mampu meningkatkan akurasi dan keandalan model prediktif. Model multimodal semacam ini menunjukkan performa yang lebih stabil karena mampu merefleksikan konteks klinis yang kompleks dan tidak tergantung semata pada pola visual citra medis.

Solusi lain yang mendapat perhatian luas adalah penerapan Explainable AI (XAI) seperti Grad-CAM dan LIME, yang mampu menyajikan peta aktivasi atau visualisasi bagian citra yang memengaruhi hasil prediksi. Dengan visualisasi ini, dokter dapat melihat secara langsung alasan di balik deteksi kanker yang dilakukan model, sehingga meningkatkan kepercayaan dan transparansi. Dalam hal generalisasi model, pendekatan ensemble learning dan transfer learning memberikan alternatif yang kuat, terutama ketika dikombinasikan dengan model pretrained seperti ResNet atau EfficientNet. Model-model ini telah dilatih sebelumnya pada data besar, sehingga lebih siap untuk menangani dataset kecil atau domain baru. Selain itu, optimasi hyperparameter secara otomatis menggunakan algoritma evolusioner (seperti TPOT atau XGBoost-RFE) mempercepat proses pengembangan model yang optimal tanpa harus melalui proses manual yang panjang dan kompleks.

KESIMPULAN

Penelitian ini menyimpulkan bahwa penerapan algoritma machine learning dalam deteksi kanker melalui citra radiografi telah menunjukkan perkembangan signifikan dalam lima tahun terakhir, dengan dominasi model deep learning seperti CNN dan turunannya. Model-model ini terbukti efektif mendeteksi berbagai jenis kanker, khususnya paru-paru dan payudara, dengan tingkat akurasi tinggi. Namun demikian, tantangan implementatif masih mengemuka, seperti keterbatasan data berkualitas tinggi, kurangnya transparansi model (black-box), hingga ketidakstabilan kinerja model di luar data pelatihan. Selain itu, belum semua studi mengintegrasikan data klinis dan citra secara utuh, yang berpotensi mengurangi relevansi prediksi dalam konteks riil pelayanan medis.

Implikasi teoretis dari studi ini menunjukkan bahwa riset di bidang radiologi berbasis ML perlu mengarah pada pengembangan model yang tidak hanya akurat, tetapi juga interpretable dan robust di berbagai domain data. Secara praktis, hasil kajian ini mendorong penyedia layanan kesehatan, pengembang teknologi, dan regulator untuk lebih aktif mendorong integrasi teknologi ML yang berbasis kebutuhan klinis dan menjunjung etika medis. Pemanfaatan explainable AI, teknik ensemble, dan transfer

learning dapat menjembatani jurang antara eksperimen akademik dan penerapan klinis yang aman dan efektif. Pemetaan sistematis ini juga membantu para pengambil kebijakan dan institusi pendidikan merancang strategi pelatihan tenaga medis agar mampu bersinergi dengan sistem diagnostik cerdas.

Sebagai saran untuk penelitian mendatang, diperlukan eksplorasi lebih lanjut terhadap pengembangan model multimodal yang menggabungkan citra dan data klinis secara real-time serta studi komparatif antar arsitektur ML dalam konteks institusi layanan kesehatan berbeda. Selain itu, pengembangan repositori data berskala nasional dan internasional yang aman serta dapat diakses secara kolaboratif menjadi kebutuhan mendesak untuk meningkatkan kualitas pelatihan model ML. Terakhir, perlu ada pendekatan transdisipliner antara ahli teknologi, radiolog, dan etikawan kesehatan untuk memastikan bahwa teknologi deteksi kanker berbasis ML tidak hanya efektif secara teknis, tetapi juga dapat diterima secara sosial dan etis dalam praktik medis global.

DAFTAR PUSTAKA

- Aarthy, R., Muthupriya, V., & Balaji, G. N. (2024). Detection of bone cancer based on a four-phase framework generative deep belief neural network in deep learning. *Alexandria Engineering Journal*, 109, 394–407. <https://doi.org/https://doi.org/10.1016/j.aej.2024.08.094>
- Angel mary, A., & Thanammal, K. K. (2024). Lung cancer detection via deep learning-based pyramid network with honey badger algorithm. *Measurement: Sensors*, 31, 100993. <https://doi.org/https://doi.org/10.1016/j.measen.2023.100993>
- Ansari, M. M., Kumar, S., Heyat, M. B. bin, Ullah, H., Hayat, M. A. bin, Sumbul, Parveen, S., Ali, A., & Zhang, T. (2025). SVMVGGNet-16: A Novel Machine and Deep Learning Based Approaches for Lung Cancer Detection using Combined SVM and VGGNet-16. *Current Medical Imaging*, 21. <https://doi.org/https://doi.org/10.2174/0115734056348824241224100809>
- Asadi, B., & Memon, Q. (2023). Efficient breast cancer detection via cascade deep learning network. *International Journal of Intelligent Networks*, 4, 46–52. <https://doi.org/https://doi.org/10.1016/j.ijin.2023.02.001>
- Choudhury, A. R., Rautray, J., Mishra, P., Kandpal, M., & Dalai, S. S. (2025). Deep Learning Based Automated Lung Cancer Detection from CT scan Leveraging Transfer Learning. *Procedia Computer Science*, 258, 2748–2759. <https://doi.org/https://doi.org/10.1016/j.procs.2025.04.535>
- Crasta, L. J., Neema, R., & Pais, A. R. (2024). A novel Deep Learning architecture for lung cancer detection and diagnosis from Computed Tomography image analysis. *Healthcare Analytics*, 5, 100316. <https://doi.org/https://doi.org/10.1016/j.health.2024.100316>
- Dana, J., McNabb, E., Castro, J., Al-Qanoobi, I., Omiya, Y., Ah-Lan, K., Fortier, V., Artho, G., Reinhold, C., & Gauvin, S. (2025). Deep learning reconstruction in biparametric prostate MRI: Impact on qualitative and radiomics analyses. *Research in Diagnostic and Interventional Imaging*, 14, 100059. <https://doi.org/https://doi.org/10.1016/j.redii.2025.100059>
- Dharani, R., & Danesh, K. (2025). Optimized deep learning ensemble for accurate oral cancer detection using CNNs and metaheuristic tuning. *Intelligence-Based Medicine*, 11, 100258. <https://doi.org/https://doi.org/10.1016/j.ibmed.2025.100258>
- Elhassan, S. M., Darwish, S. M., & Elkaffas, S. M. (2024). An Enhanced Lung Cancer Detection Approach Using Dual-Model Deep Learning Technique. *CMES - Computer Modeling in*

- Engineering and Sciences, 142(1), 835–867.
<https://doi.org/https://doi.org/10.32604/cmes.2024.058770>
- Fransen, S. J., Roest, C., van Lohuizen, Q. Y., Bosma, J. S., Simonis, F. F. J., Kwee, T. C., Yakar, D., & Huisman, H. (2024). Using deep learning to optimize the prostate MRI protocol by assessing the diagnostic efficacy of MRI sequences. *European Journal of Radiology*, 175, 111470. <https://doi.org/https://doi.org/10.1016/j.ejrad.2024.111470>
- Gawade, S., Bhansali, A., Patil, K., & Shaikh, D. (2023). Application of the convolutional neural networks and supervised deep-learning methods for osteosarcoma bone cancer detection. *Healthcare Analytics*, 3, 100153. <https://doi.org/https://doi.org/10.1016/j.health.2023.100153>
- Hammad, M., ElAffendi, M., Asim, M., Abd El-Latif, A. A., & Hashiesh, R. (2024). Automated lung cancer detection using novel genetic TPOT feature optimization with deep learning techniques. *Results in Engineering*, 24, 103448. <https://doi.org/https://doi.org/10.1016/j.rineng.2024.103448>
- Kavitha, C., Priyanka, S., Kumar, M. P., & Kusuma, V. (2024). Skin Cancer Detection and Classification using Deep Learning Techniques. *Procedia Computer Science*, 235, 2793–2802. <https://doi.org/https://doi.org/10.1016/j.procs.2024.04.264>
- Kumar, G., & Alqahtani, H. (2021). Deep Learning-Based Cancer Detection-Recent Developments, Trend and Challenges. *CMES - Computer Modeling in Engineering and Sciences*, 130(3), 1271–1307. <https://doi.org/https://doi.org/10.32604/cmes.2022.018418>
- Kumar, S., Singh, J., Ravi, V., Singh, P., al Mazroa, A., Diwakar, M., & Gupta, I. (2024). Deep Learning and MRI Biomarkers for Precise Lung Cancer Cell Detection and Diagnosis. *The Open Bioinformatics Journal*, 17. <https://doi.org/https://doi.org/10.2174/0118750362335415240909061539>
- Kumar, V., K T, C., Jagini, N. P., Rajkumar, K. V., Godi, R. K., & Tumuluru, P. (2025). Enhanced breast cancer detection and classification via CAMR-Gabor filters and LSTM: A deep Learning-Based method. *Egyptian Informatics Journal*, 29, 100602. <https://doi.org/https://doi.org/10.1016/j.eij.2024.100602>
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., ... & van Ginneken, B. (2017). A survey on deep learning in medical image analysis. *Medical image analysis*, 42, 60–88. <https://doi.org/10.1016/j.media.2017.07.005>
- Lokaj, B., Durand de Gevigney, V., Djema, D.-A., Zaghir, J., Goldman, J.-P., Bjelogrljic, M., Turbé, H., Kinkel, K., Lovis, C., & Schmid, J. (2025). Multimodal deep learning fusion of ultrafast-DCE MRI and clinical information for breast lesion classification. *Computers in Biology and Medicine*, 188, 109721. <https://doi.org/https://doi.org/10.1016/j.compbimed.2025.109721>
- Malibari, A. A., Obayya, M., Nour, M. K., Mehanna, A. S., Hamza, M. A., Zamani, A. S., Yaseen, I., & Motwakel, A. (2022). Gaussian Optimized Deep Learning-based Belief Classification Model for Breast Cancer Detection. *Computers, Materials and Continua*, 73(2), 4123–4138. <https://doi.org/https://doi.org/10.32604/cmc.2022.030492>
- McBee, M. P., Awan, O. A., Colucci, A. T., Ghobadi, C. W., Kadom, N., Kansagra, A. P., & Tridandapani, S. (2018). Deep learning in radiology. *Academic radiology*, 25(11), 1472–1480. <https://doi.org/10.1016/j.acra.2018.02.018>
- Mesropyan, N., Katemann, C., Leutner, C., Sommer, A., Isaak, A., Weber, O. M., Peeters, J. M., Dell, T., Bischoff, L., Kuetting, D., Pieper, C. C., Lakghomi, A., & Luetkens, J. A. (2025). Accelerated High-resolution T1- and T2-weighted Breast MRI with Deep Learning Super-resolution Reconstruction. *Academic Radiology*, 32(6), 3147–3156. <https://doi.org/https://doi.org/10.1016/j.acra.2024.12.055>

- Miotto, R., Wang, F., Wang, S., Jiang, X., & Dudley, J. T. (2017). Deep learning for healthcare: review, opportunities and challenges. *Briefings in bioinformatics*, 19(6), 1236–1246. <https://doi.org/10.1093/bib/bbx044>
- Mishra, K. N., Mishra, A., Ray, S., Kumari, A., & Waris, S. M. (2024). Enhancing cancer detection and prevention mechanisms using advanced machine learning approaches. *Informatics in Medicine Unlocked*, 50, 101579. <https://doi.org/https://doi.org/10.1016/j.imu.2024.101579>
- Nguyen-Tat, T. B., Hung, T. Q., Nam, P. T., & Ngo, V. M. (2025). Evaluating pre-processing and deep learning methods in medical imaging: Combined effectiveness across multiple modalities. *Alexandria Engineering Journal*, 119, 558–586. <https://doi.org/https://doi.org/10.1016/j.aej.2025.01.090>
- Nobel, S. M. N., Sultana, S., Tasir, M. A. M., Mridha, M. F., & Aung, Z. (2025). CancerNet: A comprehensive deep learning framework for precise and intelligible cancer identification. *Computers in Biology and Medicine*, 193, 110339. <https://doi.org/https://doi.org/10.1016/j.compbimed.2025.110339>
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., ... & Moher, D. (2021). The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *BMJ*, 372, n71. <https://doi.org/10.1136/bmj.n71>
- Rajpurkar, P., Irvin, J., Ball, R. L., Zhu, K., Yang, B., Mehta, H., ... & Ng, A. Y. (2018). Deep learning for chest radiograph diagnosis: A retrospective comparison of the CheXNeXt algorithm to practicing radiologists. *PLoS medicine*, 15(11), e1002686. <https://doi.org/10.1371/journal.pmed.1002686>
- Reschke, P., Koch, V., Gruenewald, L. D., Bachir, A. A., Gotta, J., Booz, C., Alrahmoun, M. A., Strecker, R., Nickel, D., D'Angelo, T., Dahm, D. M., Konrad, P., Solim, L. A., Holzer, M., Al-Saleh, S., Scholtz, J.-E., Sommer, C. M., Hammerstingl, R. M., Eichler, K., ... Mahmoudi, S. (2025). Deep Learning-Accelerated Prostate MRI: Improving Speed, Accuracy, and Sustainability. *Academic Radiology*. <https://doi.org/https://doi.org/10.1016/j.acra.2025.06.022>
- Sharma, D., Choubey, D. K., & Thakur, K. (2025). Lung and Colon Cancer Detection using Deep Learning Techniques. *Procedia Computer Science*, 258, 4136–4146. <https://doi.org/https://doi.org/10.1016/j.procs.2025.04.664>
- Shatnawi, M. Q., Abuein, Q., & Al-Quraan, R. (2025). Deep learning-based approach to diagnose lung cancer using CT-scan images. *Intelligence-Based Medicine*, 11, 100188. <https://doi.org/https://doi.org/10.1016/j.ibmed.2024.100188>
- Sreeprada, V., & Vedavathi, Dr. K. (2023). Lung Cancer Detection from X-Ray Images using Hybrid Deep Learning Technique. *Procedia Computer Science*, 230, 467–474. <https://doi.org/https://doi.org/10.1016/j.procs.2023.12.102>
- Taguelmimt, K., Andrade-Miranda, G., Harb, H., Thanh, T. T., Dang, H.-P., Malavaud, B., & Bert, J. (2025). Towards more reliable prostate cancer detection: Incorporating clinical data and uncertainty in MRI deep learning. *Computers in Biology and Medicine*, 194, 110440. <https://doi.org/https://doi.org/10.1016/j.compbimed.2025.110440>
- Thapa, M., & Kaur, R. (2025). An Explainable Deep – Learning based Multi-Label Image Classification for Chest X-Rays. *Procedia Computer Science*, 258, 2425–2434. <https://doi.org/https://doi.org/10.1016/j.procs.2025.04.505>
- Tjoa, E., & Guan, C. (2020). A survey on explainable artificial intelligence (XAI): Toward medical XAI. *IEEE Transactions on Neural Networks and Learning Systems*, 32(11), 4793–4813. <https://doi.org/10.1109/TNNLS.2020.3027314>

- Yan, L. J., Wu, L., Xia, M., & He, L. (2025). A hybrid deep learning model for mammographic breast cancer detection: Multi-autoencoder and attention mechanisms. *Journal of Radiation Research and Applied Sciences*, 18(3), 101578. <https://doi.org/https://doi.org/10.1016/j.jrras.2025.101578>
- Zhang, X., & Lee, V. C. S. (2024). Deep Learning Empowered Decision Support Systems for Thyroid Cancer Detection and Management. *Procedia Computer Science*, 237, 945–954. <https://doi.org/https://doi.org/10.1016/j.procs.2024.05.183>