

Systematic Literature Review terhadap Implementasi Deep Learning dalam Diagnosis Awal Tuberkulosis

Aisyah Shinta Balqis^{1*}, Muh. Ramli², Nur Inda³, Nurhidayah⁴

¹Informatika, Institut Teknologi Dan Bisnis Muhammadiyah Polewali Mandar, Sulawesi Barat, Indonesia

²Informatika, Institut Teknologi Dan Bisnis Muhammadiyah Polewali Mandar, Sulawesi Barat, Indonesia

³Informatika, Institut Teknologi Dan Bisnis Muhammadiyah Polewali Mandar, Sulawesi Barat, Indonesia

⁴Informatika, Institut Teknologi Dan Bisnis Muhammadiyah Polewali Mandar, Sulawesi Barat, Indonesia

¹aisyah.shinta@itbmpolman.ac.id

²ramli@itbmpolman.ac.id

³nurinda@itbmpolman.ac.id

⁴nurhidayah.inf125@itbmpolman.ac.id

*Corresponding Author:

aisyah.shinta@itbmpolman.ac.id

(Received: 22-06-2026, Accepted: 29-06-2026, Published: 30-06-2026)

Abstrak

Tuberkulosis (TB) tetap menjadi ancaman kesehatan global yang signifikan, terutama di negara berkembang yang memiliki keterbatasan akses terhadap teknologi diagnostik yang andal. Ketidakseimbangan data dan kesulitan dalam mendiagnosis penyakit ini sejak dini menjadi tantangan utama. Penelitian ini bertujuan untuk mengidentifikasi metode *Deep Learning* (DL) yang tersedia, mengevaluasi berbagai arsitektur jaringan saraf yang digunakan, dan menentukan model yang paling efektif untuk deteksi dini TB. Metode yang digunakan meliputi pencarian literatur di database Scopus dan Google Scholar dengan kata kunci terkait. Seleksi dan penyaringan dilakukan berdasarkan kriteria inklusi dan eksklusi yang ketat, dengan 52 studi terpilih dievaluasi dan dianalisis untuk memberikan gambaran komprehensif tentang implementasi DL dalam diagnosa awal TB. Hasil penelitian menunjukkan bahwa metode *Convolutional Neural Networks* (CNNs) seperti ResNet, VGG, dan DenseNet adalah yang paling sering digunakan dan menunjukkan kinerja unggul. Kombinasi teknik *Transfer Learning* dan *Generative Adversarial Networks* (GANs) terbukti efektif dalam meningkatkan akurasi dan mengatasi masalah ketidakseimbangan data. ResNet50 muncul sebagai model yang paling efektif dengan akurasi hingga 98.20%. Saran untuk peneliti selanjutnya adalah untuk fokus pada peningkatan interpretabilitas model DL dan pengembangan dataset yang lebih besar dan representatif. Selain itu, integrasi teknik AI dengan sistem kesehatan yang ada dapat membantu menciptakan alat diagnostik yang lebih komprehensif dan mudah diakses.

Kata Kunci: *Deep Learning; Tuberkulosis; Convolutional Neural Networks; Transfer Learning; Generative Adversarial Networks.*

Abstract

Tuberculosis (TB) remains a significant global health threat, particularly in developing countries with limited access to reliable diagnostic technology. Data imbalance and difficulties in early diagnosis are major challenges. This study aims to identify available Deep Learning (DL) methods, evaluate various neural network architectures used, and determine the most effective model for early TB detection. The methods used included a literature search in Scopus and Google Scholar databases using relevant keywords. Selection and screening were conducted based on strict inclusion and exclusion criteria, with 52 selected studies evaluated and analyzed to provide a comprehensive overview of DL implementation in early TB diagnosis. The results showed that Convolutional Neural Networks (CNNs) methods such as ResNet, VGG, and DenseNet were the most frequently used and demonstrated superior performance. The combination of Transfer Learning and Generative Adversarial Networks (GANs) techniques proved effective in improving accuracy and addressing data imbalance issues. ResNet50 emerged as the most effective model with an accuracy of up to 98.20%. Suggestions for future researchers include focusing on improving the interpretability of DL models and developing larger, more representative datasets.

Furthermore, integrating AI techniques with existing healthcare systems could help create more comprehensive and accessible diagnostic tools.

Keywords: *Deep Learning; Tuberculosis; Convolutional Neural Networks; Transfer Learning; Generative Adversarial Networks.*

1. PENDAHULUAN

Penyakit paru-paru sering kali dikaitkan dengan rasa sakit dan penderitaan yang menyiksa karena mempengaruhi pola pernapasan pasien, yang dapat menyebabkan sesak napas dan gejala terkait [1]. Salah satu penyakit paru-paru yang serius adalah tuberkulosis (TB), penyakit menular yang sangat mudah menyebar. TB ditularkan melalui udara ketika orang yang terinfeksi batuk, bersin, atau meludah. Penyakit ini disebabkan oleh bakteri *Mycobacterium tuberculosis*.

Tuberkulosis (TBC) merupakan ancaman kesehatan utama, terutama bagi orang dewasa di negara-negara berkembang seperti di Afrika dan Asia Tenggara [2]. Menurut Organisasi Kesehatan Dunia (WHO), sekitar 11 juta orang di seluruh dunia menderita TB pada tahun 2019, dan 1,5 juta orang meninggal akibat penyakit ini. Deteksi dini dan akurat sangat penting untuk mengendalikan perkembangan TB dan mencegah penularan lebih lanjut [3]. Gejala yang mungkin dialami oleh orang yang terinfeksi termasuk demam, penurunan berat badan, batuk, dan keringat malam.

Secara global, pneumonia adalah penyebab utama kematian anak-anak dan dapat disebabkan oleh bakteri atau virus. Untungnya, antibiotik dan obat antivirus efektif dalam mengobati infeksi paru-paru ini [4]. Salah satu strategi efektif untuk mengendalikan TBC adalah skrining sistemik, yang dapat membedakan orang dengan risiko tinggi tertular TBC dari mereka yang tidak berisiko tinggi [5].

Dengan semakin mendesaknya perhatian global terhadap penyakit ini, kita menyadari pentingnya pendekatan komputasi baru dalam penelitian dasar dan biomedis untuk mengurangi TB secara substansial [6]. Tes diagnostik modern bergantung pada prosedur laboratorium yang mahal dan memerlukan peralatan khusus [7]. Jenis TBC yang resistan terhadap obat menjadi perhatian khusus dalam diagnosis dan pengobatan. Saat ini, ada sekitar 20 obat yang digunakan untuk mengobati tuberkulosis [8]. Kemajuan dalam pembelajaran mendalam telah memungkinkan peneliti untuk menggunakan teknik canggih ini dalam mengklasifikasikan atau menganalisis rontgen dada secara efektif [9].

Standar emas untuk diagnosis tuberkulosis adalah kultur dahak. Sayangnya, banyak negara di mana penyakit ini umum terjadi memiliki akses yang buruk terhadap tes diagnostik ini [10]. Dalam praktik klinis, rontgen dada biasanya diperiksa oleh dokter berpengalaman untuk mendeteksi TBC. Namun, proses ini memakan waktu dan bersifat subjektif [11]. Dengan kemajuan teknologi, implementasi *Deep Learning* dalam bidang kesehatan telah menunjukkan potensi besar dalam meningkatkan akurasi diagnosis penyakit infeksi seperti TB. Meskipun terdapat beberapa model deteksi TB berbasis pembelajaran mendalam dalam literatur, keakuratan sebagian besar model tersebut masih rendah, rata-rata sekitar 80% [12].

Selama 10 tahun terakhir, sistem diagnostik berbasis kecerdasan buatan (AI) telah berkembang pesat dan mulai digunakan dalam pengaturan klinis. Banyak algoritma AI untuk analisis gambar medis dikembangkan berdasarkan pemahaman mendalam yang terus meningkat [13]. AI kini digunakan untuk mengotomatisasi diagnosis banyak penyakit, dan telah terbukti mencapai kinerja unggul dalam kategorisasi gambar otomatis menggunakan berbagai algoritma pembelajaran mesin [14]. Penerapan metode pembelajaran mesin untuk diagnosis otomatis di bidang medis baru-baru ini menjadi populer sebagai alat tambahan bagi dokter [15]. Lesi tuberkulosis paru memiliki morfologi yang beragam, sehingga analisisnya sulit diukur [16].

Secara historis, sistem diagnosis berbantuan komputer (CAD) untuk penyakit terutama bergantung pada teknologi ekstraksi fitur dan pengenalan pola [17]. Sistem CAD untuk diagnosis (CADx) dan deteksi (CADE) telah terbukti meningkatkan keakuratan diagnosis medis, mengurangi hasil positif dan negatif palsu, serta mengurangi waktu interpretasi [18]. Beberapa penelitian CAD yang menangani kelainan pada rontgen dada (CXR) tidak berfokus pada penyakit lain selain TB. Namun, sebagian besar sistem CAD yang mengkhususkan diri dalam deteksi TB telah dilaporkan [19]. Sistem CAD sangat penting untuk meningkatkan efektivitas diagnostik CXR dalam skrining TB di daerah terpencil dengan sumber daya terbatas [20]. Selain itu, beberapa solusi perangkat lunak CAD telah dikembangkan untuk menganalisis CXR digital guna mendeteksi anomali yang mengarah pada TB [21].

Banyak penelitian telah mengeksplorasi berbagai aspek penerapan *Deep Learning* dalam diagnosis TB, seperti menilai efektivitas metode deteksi berbasis citra medis [22][23], merancang arsitektur jaringan saraf mendalam yang inovatif [24], dan mengatasi tantangan penerapan teknologi ini di negara-negara dengan sumber daya terbatas [9]. *Deep Learning* berasal dari jaringan saraf konvensional tetapi kinerjanya jauh lebih

unggul [25] Model pembelajaran mendalam banyak digunakan dalam sistem perawatan kesehatan modern [26]. Pembelajaran mesin (ML) memungkinkan algoritme komputer belajar dan meningkatkan kinerjanya secara otomatis dari pengalaman tanpa diprogram secara eksplisit [27]. Meskipun studi-studi ini telah memberikan wawasan berharga, masih diperlukan tinjauan komprehensif dan terkini yang mensintesis literatur terkait implementasi *Deep Learning* dalam diagnosis awal TB. Deteksi objek, salah satu masalah paling mendasar dan menantang dalam visi komputer, berupaya menemukan lokasi objek dari sejumlah besar kategori yang telah ditentukan sebelumnya dalam gambar alami [28].

Beberapa penelitian review telah membahas pemanfaatan Artificial Intelligence pada penyakit paru ataupun Deep Learning untuk medical imaging secara umum. Akan tetapi sebagian besar masih bersifat naratif, mencakup berbagai penyakit sekaligus, atau dilakukan sebelum munculnya berbagai arsitektur Deep Learning terbaru seperti EfficientNet, Vision Transformer maupun model berbasis Explainable AI. Oleh karena itu diperlukan tinjauan literatur sistematis yang lebih mutakhir.

Mengidentifikasi kesenjangan penelitian dan memahami perkembangan topik ini sangat penting untuk memperdalam pemahaman kita tentang bagaimana teknologi dapat dioptimalkan untuk mendeteksi TB dengan lebih akurat dan efisien. Alat otomatis dapat mendeteksi berbagai jenis kelainan dada dalam hitungan detik dan sangat berguna untuk penyaringan populasi, terutama di daerah yang kekurangan tenaga medis ahli [29].

Meskipun banyak penelitian telah dilakukan, masih jarang ada tinjauan literatur sistematis yang fokus pada penerapan *Deep Learning* untuk diagnosis awal TB. Oleh karena itu, penelitian ini bertujuan untuk mengisi kekosongan tersebut dengan melakukan tinjauan literatur sistematis guna mengidentifikasi, mengkategorikan, dan menganalisis kondisi penelitian saat ini mengenai *Deep Learning* dalam diagnosis TB secara menyeluruh. Melalui tinjauan ini, kami berupaya memahami tren terbaru, dampak, sumber-sumber yang relevan, dan tema umum dalam literatur. Selain itu, kami juga ingin mengidentifikasi kesenjangan dan area yang memerlukan penelitian lebih lanjut, sehingga dapat berkontribusi pada perbaikan dan pengembangan riset di bidang ini di masa depan.

Berbagai penelitian sebelumnya telah berhasil mengembangkan model Deep Learning untuk mendeteksi Tuberkulosis menggunakan citra Chest X-Ray dengan tingkat akurasi yang tinggi. Sebagian besar penelitian berfokus pada pengembangan model tertentu seperti ResNet, DenseNet, EfficientNet maupun Transfer Learning. Namun penelitian-penelitian tersebut masih bersifat parsial dan hanya mengevaluasi performa model secara individual sehingga belum memberikan gambaran komprehensif mengenai perkembangan metode Deep Learning dalam diagnosis Tuberkulosis.

Kebaruan penelitian ini terletak pada sintesis sistematis terhadap penelitian Deep Learning untuk diagnosis awal Tuberkulosis selama periode 2019–2024 dengan menggunakan metode PRISMA. Selain membandingkan performa berbagai arsitektur Deep Learning, penelitian ini juga mengidentifikasi tren penelitian, tantangan implementasi, serta peluang pengembangan model di masa depan.

Penelitian ini bertujuan untuk mengidentifikasi metode *Deep Learning* yang tersedia, mengevaluasi berbagai arsitektur jaringan saraf yang digunakan untuk mendiagnosis TB, dan menentukan model yang paling efektif untuk deteksi awal penyakit ini.

2. METODE PENELITIAN

2.1 Pertanyaan Penelitian

Penelitian ini berfokus pada eksplorasi dan evaluasi implementasi *Deep Learning* dalam diagnosa awal penyakit TB.

Pertanyaan penelitian yang diajukan adalah:

RQ1. Seberapa banyak metode *Deep Learning* yang dapat digunakan dalam diagnosa awal penyakit TB?

RQ2. Apa saja arsitektur jaringan saraf mendalam yang telah dikembangkan atau disesuaikan khusus untuk mendiagnosa TB pada tahap awal, dan bagaimana performanya?


RQ3. Model *Deep Learning* apa yang paling efektif digunakan dalam Diagnosa Awal Penyakit Tuberkulosis?

Penelitian ini bertujuan untuk melakukan tinjauan literatur sistematis mengenai implementasi *Deep Learning* dalam diagnosa awal penyakit Tuberkulosis (TB). Strategi pencarian dan seleksi literatur dilakukan dengan mengikuti beberapa langkah yang sistematis dan terstruktur.

2.2 Tahapan Penelitian

Tahapan penelitian yang sistematis dalam mengeksplorasi metode *Deep Learning* untuk diagnosis awal Tuberkulosis (TBC). Seperti yang terlihat pada gambar 2.1. Proses ini dimulai dengan

identifikasi topik penelitian yang menetapkan fokus pada penggunaan teknologi *Deep Learning* untuk mendeteksi TBC secara dini, mengingat pentingnya diagnosa yang lebih akurat dan efektif.



Gambar 2. 1 Tahapan Penulisan Artikel SLR (Systematic Literature Review)

Setelah topik ditetapkan, langkah selanjutnya adalah pencarian literatur menggunakan database terkenal seperti Scopus dan Google Scholar dengan kata kunci "*Deep Learning*" dan "*Tuberculosis Diagnosis*". Proses ini bertujuan untuk mengumpulkan artikel yang relevan sesuai dengan topik penelitian yang telah ditentukan.

Kemudian dilakukan seleksi dan penyaringan literatur, di mana artikel yang dikumpulkan disaring untuk memastikan kesesuaiannya dengan topik penelitian dan kata kunci yang dibutuhkan. Proses ini diilustrasikan lebih lanjut dalam Tabel 2.1 yang merinci kriteria inklusi dan eksklusi yang digunakan dalam penelitian ini.

Kriteria inklusi dalam penelitian ini mencakup studi yang menggunakan metode *Deep Learning* untuk diagnosis awal Tuberkulosis (TBC) dan penyakit paru-paru. Penelitian yang dimasukkan harus berasal dari jurnal dan publikasi konferensi akademik yang terindeks pada database terkenal seperti Scopus, dan Google Scholar. Selain itu, hanya studi yang diterbitkan dalam kurun waktu lima tahun terakhir (2019-2024) yang akan dipertimbangkan. Artikel yang dipilih juga harus ditulis dalam Bahasa Indonesia atau Bahasa Inggris untuk memastikan kesesuaian dan relevansi dengan topik penelitian.

Di sisi lain, kriteria eksklusi mencakup studi yang tidak berfokus pada penyakit Paru-Paru. Review articles atau survey papers yang tidak memberikan kontribusi empiris baru, seperti preprints, artikel blog, atau opini, juga akan dikecualikan dari penelitian ini. Selain itu, studi yang diterbitkan di luar lima tahun terakhir tidak akan dipertimbangkan. Artikel yang ditulis dalam bahasa selain Bahasa Indonesia atau Bahasa Inggris juga akan dikecualikan dari analisis.

Tabel 2. 1 Kriteria, Inklusi dan Eksklusi

Kriteria	Inklusi	Eksklusi
Relevansi	Studi ini menggunakan <i>Deep Learning</i> untuk diagnosis Penyakit Paru-Paru.	Studi yang tidak berfokus pada Penyakit Paru-Paru.
Tipe Dokumen	Jurnal Publikasi Konferensi akademik yang terindeks pada database terkenal (misalnya IEEE Xplore, PubMed, Google Scholar).	Review articles atau survey papers yang tidak memberikan kontribusi empiris baru. (misalnya preprints, artikel blog, atau opini).
Periode Publikasi	Studi yang diterbitkan dalam kurun waktu 5 tahun terakhir (2019-2024).	Studi yang diterbitkan diluar 5 tahun terakhir.

Bahasa	Bahasa Indonesia, English	Selain Keduanya
--------	---------------------------	-----------------

Selanjutnya, artikel yang lolos seleksi dievaluasi kualitasnya berdasarkan kesesuaian topik studi, rentang waktu publikasi, dan bahasa artikel. Tahap ini memastikan bahwa hanya artikel berkualitas tinggi yang dimasukkan ke dalam analisis.

Proses berikutnya adalah ekstraksi data, di mana informasi yang diperlukan diambil menggunakan formulir ekstraksi data. Data yang diperoleh dianalisis dan disintesiskan untuk menggabungkan dan membandingkan hasil-hasil dari evaluasi performa metode *Deep Learning* yang dijelaskan dalam artikel-artikel yang terpilih.


Tahap terakhir adalah penulisan tinjauan literatur, di mana laporan harus mencakup semua temuan yang relevan dari tinjauan literatur. Ini termasuk informasi tentang metode *Deep Learning* yang digunakan, hasil evaluasi performa, analisis data, serta kesimpulan yang ditarik.

Proses yang sistematis ini, seperti yang diilustrasikan dalam Gambar 1 dan dirangkum dalam Tabel 1, memastikan bahwa penelitian dilakukan dengan cara yang terstruktur dan komprehensif. Hal ini memungkinkan untuk memberikan wawasan yang mendalam dan terpercaya mengenai implementasi *Deep Learning* dalam diagnosis awal TBC.

2.3 Pengumpulan Data

Penelitian ini mengikuti pedoman Preferred Reporting Items for Systematic Reviews and Meta-Analyses (PRISMA) untuk menjamin proses identifikasi dan seleksi literatur dilakukan secara transparan serta dapat direplikasi, seperti yang digambarkan pada Gambar 2.2. Langkah-langkah metode penelitian ini meliputi kegiatan berikut:

Tahap pertama adalah **Identification**, yaitu proses mengidentifikasi seluruh artikel yang berpotensi relevan melalui pencarian pada dua basis data, yaitu Scopus dan Google Scholar. Kedua basis data dipilih karena memiliki cakupan publikasi ilmiah yang luas pada bidang kesehatan dan kecerdasan buatan. Berdasarkan hasil pencarian menggunakan kata kunci yang telah ditentukan, diperoleh 135 artikel dari Scopus dan 100 artikel dari Google Scholar sehingga total artikel yang berhasil diidentifikasi sebanyak 235 artikel. Selanjutnya dilakukan proses identifikasi duplikasi menggunakan perangkat lunak Covidence sehingga diperoleh 4 artikel duplikat yang dihapus. Dengan demikian sebanyak 231 artikel dilanjutkan ke tahap penyaringan.



Gambar 2. 2 Tahapan Screening dengan metode PRISMA

Tahap kedua adalah Screening, yaitu proses penyaringan berdasarkan judul dan abstrak. Pada tahap ini setiap artikel dievaluasi berdasarkan relevansinya terhadap topik implementasi *Deep Learning*

dalam diagnosis awal Tuberkulosis. Artikel yang tidak membahas diagnosis TB, tidak menggunakan metode Deep Learning, atau tidak sesuai dengan tujuan penelitian dieliminasi. Dari 231 artikel yang diseleksi, sebanyak 92 artikel dikeluarkan sehingga tersisa 139 artikel untuk dilakukan penilaian kelayakan secara penuh.

Tahap berikutnya adalah Eligibility, yaitu evaluasi terhadap teks lengkap (full-text assessment). Pada tahap ini setiap artikel diperiksa berdasarkan kriteria inklusi dan eksklusi yang telah ditetapkan, meliputi periode publikasi, jenis dokumen, bahasa, kesesuaian topik, serta ketersediaan informasi mengenai metode dan hasil penelitian. Sebanyak 82 artikel dieliminasi karena tidak memenuhi satu atau lebih kriteria tersebut sehingga tersisa 52 artikel yang memenuhi syarat untuk dianalisis lebih lanjut.

Tahap terakhir adalah Included, yaitu penetapan artikel yang digunakan sebagai sumber utama dalam proses sintesis. Sebanyak 52 artikel yang lolos seluruh tahapan seleksi selanjutnya diekstraksi datanya dan dianalisis untuk menjawab seluruh research question yang telah dirumuskan. Tahapan ini memastikan bahwa hanya literatur yang relevan, berkualitas, dan sesuai dengan tujuan penelitian yang digunakan dalam proses sintesis.

Proses ini memastikan bahwa hanya studi-studi yang paling relevan dan berkualitas tinggi yang diikutsertakan, sehingga hasil penelitian yang diperoleh dapat dipercaya dan memberikan wawasan yang komprehensif.

Seluruh proses identifikasi artikel duplikat, screening judul dan abstrak, serta penilaian full-text dilakukan menggunakan perangkat lunak Covidence. Penggunaan perangkat lunak ini membantu menjaga konsistensi proses seleksi, mempermudah dokumentasi setiap keputusan screening, dan mengurangi potensi kesalahan selama proses Systematic Literature Review.

3. HASIL DAN PEMBAHASAN

Penelitian ini bertujuan untuk mengkaji penggunaan metode *Deep Learning* dalam diagnosa awal penyakit Tuberkulosis (TB) melalui analisis terhadap 50 artikel ilmiah. Diagnosa dini TB sangat penting untuk mengurangi penularan dan meningkatkan keberhasilan pengobatan. Teknik-teknik *Deep Learning* telah menunjukkan potensi besar dalam berbagai aplikasi medis, termasuk dalam mendeteksi penyakit paru-paru seperti TB. Dengan pertanyaan penelitian yang terfokus pada jumlah metode yang dapat digunakan, arsitektur jaringan yang telah dikembangkan, serta efektivitas model-model yang ada, penelitian ini memberikan gambaran komprehensif tentang state-of-the-art dalam diagnosa awal TB menggunakan *Deep Learning*.

RQ1. Seberapa banyak metode *Deep Learning* yang dapat digunakan dalam diagnosa awal penyakit TB?

Analisis terhadap 52 artikel mengungkapkan bahwa terdapat berbagai metode *Deep Learning* yang digunakan untuk diagnosa awal TB. Metode yang paling umum meliputi:


Tabel 3. 1 Jumlah studi dan persentase metode *Deep Learning* pada TBC

Metode <i>Deep Learning</i>	Jumlah Studi	Persentase
<i>Convolutional Neural Networks</i> (CNNs)	30	57.69%
<i>Transfer Learning</i>	10	19.23%
<i>Generative Adversarial Networks</i> (GANs)	5	9.62%
Hybrid Models	3	5.77%
Recurrent Neural Networks (RNNs)	4	7.69%
Total	52	100%

Dalam upaya meningkatkan efektivitas deteksi dini Tuberkulosis (TBC), berbagai metode *Deep Learning* telah diterapkan. Berdasarkan data pada Tabel 3.1, salah satu metode yang paling sering digunakan

adalah *Convolutional Neural Networks* (CNNs). CNNs dikenal karena kemampuannya yang luar biasa dalam mengenali pola pada gambar medis, terutama gambar X-ray dada. Studi menunjukkan bahwa CNNs dapat mencapai akurasi tinggi dalam mendeteksi TBC. Model-model seperti ResNet, VGG, dan DenseNet adalah beberapa contoh arsitektur CNN yang digunakan secara luas dan telah menunjukkan performa unggul dalam diagnosis TBC [30][31][23]. Karena munculnya varian jaringan baru dan penggunaan GPU modern, minat terhadap CNN telah meningkat pesat dalam beberapa tahun terakhir [32].

Desain arsitektur CNN terinspirasi oleh karya Hubel dan Wiesel dan sebagian besar mengikuti struktur dasar korteks visual primate [33]. Mekanisme perhatian saluran telah terbukti menawarkan potensi besar dalam meningkatkan kinerja CNN [34]. Pada pendekatan deteksi TBC berbasis CNN sebelumnya, bobot lapisannya diambil dari beberapa model terlatih yang telah disetel dengan baik, dan fitur yang diekstraksi dari lapisan tersebut digabungkan untuk membuat model ansambel pembelajaran mendalam [35]. Algoritma pembelajaran mesin tradisional menggunakan fitur buatan tangan yang terbatas pada masalah atau kumpulan data tertentu karena memerlukan ekstraksi fitur berbasis ahli [36]. Berdasarkan CNN dan penyematan grafik, varian jaringan saraf grafik (GNN) diusulkan untuk mengumpulkan informasi secara kolektif dari struktur grafik [37].



Gambar 3. 1 Distribusi metode Deep Learning dalam studi TBC

Selain CNN, *Transfer Learning* juga memainkan peran penting dalam deteksi TBC, seperti yang digambarkan pada grafik gambar 3.1. Teknik ini melibatkan penggunaan model yang telah dilatih sebelumnya pada dataset besar untuk diaplikasikan pada tugas spesifik seperti deteksi TBC. *Transfer Learning* sangat efektif ketika dataset yang tersedia terbatas, karena dapat memanfaatkan pengetahuan yang sudah ada dari model yang lebih umum. Model seperti ResNet50, VGG16, dan DenseNet-169 sering digunakan dengan teknik ini dan menunjukkan peningkatan kinerja yang signifikan [38][39].

Untuk mengatasi masalah ketidakseimbangan data, *Generative Adversarial Networks* (GANs) digunakan. GANs mampu menghasilkan gambar tambahan yang dapat digunakan untuk pelatihan, sehingga meningkatkan ukuran dataset dan mengurangi overfitting, yang merupakan masalah umum dalam pelatihan model *Deep Learning* [13][40].

Beberapa studi juga mengeksplorasi penggunaan Hybrid Models, yaitu penggabungan berbagai teknik untuk meningkatkan akurasi deteksi. Misalnya, model yang menggabungkan teknik histogram equalization dan segmentasi paru-paru sebelum pelatihan dengan CNN menunjukkan peningkatan kinerja yang signifikan [41].

Meskipun lebih jarang digunakan dibandingkan dengan CNN, Recurrent Neural Networks (RNN) juga diterapkan dalam beberapa studi untuk analisis data temporal yang berkaitan dengan deteksi penyakit. RNN memiliki kemampuan unik dalam menangani data berurutan, yang sangat berguna dalam analisis perkembangan penyakit dari waktu ke waktu [9].

Secara keseluruhan, berbagai teknik *Deep Learning* ini saling melengkapi dalam upaya meningkatkan akurasi dan efisiensi deteksi dini TBC, menunjukkan potensi besar dalam penerapan teknologi canggih untuk kesehatan masyarakat.

RQ2. Apa saja arsitektur jaringan saraf mendalam yang telah dikembangkan atau disesuaikan khusus untuk mendiagnosa TB pada tahap awal, dan bagaimana performanya?

Berikut adalah arsitektur jaringan saraf mendalam yang telah dikembangkan atau disesuaikan untuk diagnosa TB beserta performanya:


Tabel 3. 2 Jumlah studi dan akurasi arsitektur jaringan saraf dalam diagnosa TBC.

Arsitektur Jaringan Saraf Mendalam	Akurasi (%)	Jumlah Studi
ResNet50	98.2%	15
VGG (VGG16, VGG19)	Bervariasi	12
DenseNet-169	Sangat Baik	10
Xception	Signifikan	8
Conditional Generative Adversarial Networks (cGAN)	94.21%	7
Total		52

Pada Tabel 3.2, terlihat bahwa salah satu arsitektur *Deep Learning* yang sering diandalkan dalam diagnosis Tuberkulosis (TBC) adalah ResNet (Residual Networks). ResNet, terutama varian ResNet50 dan ResNet101, telah menunjukkan performa yang luar biasa. Dalam beberapa studi, ResNet50 berhasil mencapai akurasi hingga 98.20% [30][42]. Keunggulan utama dari ResNet adalah kemampuannya mengatasi masalah vanishing gradient, yang memungkinkan pelatihan jaringan yang sangat dalam tanpa kehilangan akurasi.

Selanjutnya, model VGG (Visual Geometry Group) juga banyak digunakan dalam berbagai penelitian. Model VGG16 dan VGG19, meskipun memiliki struktur yang lebih sederhana, terbukti efektif dalam klasifikasi gambar medis. Hasil studi menunjukkan bahwa performa VGG bervariasi tergantung pada dataset dan teknik pra-pemrosesan yang digunakan [43][23].

Berikutnya, DenseNet (Densely Connected Convolutional Networks) adalah arsitektur lain yang menunjukkan kinerja unggul dalam mendeteksi TBC. DenseNet-169 dan DenseNet-201, khususnya, memberikan hasil yang sangat baik ketika diterapkan dengan teknik *Transfer Learning*. Kelebihan DenseNet terletak pada konektivitas yang padat antar lapisan, yang memungkinkan propagasi informasi lebih efisien dan mengurangi risiko overfitting [30][42].



Gambar 3. 2 Kinerja dan penggunaan arsitektur jaringan saraf dalam diagnosa TBC

Di sisi lain, berdasarkan grafik pada gambar 3.2, Xception juga digunakan dalam beberapa studi dengan hasil yang signifikan. Model ini merupakan ekstensi dari arsitektur Inception dan memanfaatkan depthwise separable convolutions untuk meningkatkan efisiensi dan akurasi [44]. Penggunaan Xception menunjukkan bahwa arsitektur yang lebih baru dan inovatif dapat memberikan keuntungan tambahan dalam diagnosis TBC.

Untuk mengatasi masalah overfitting dan keterbatasan data, Conditional Generative Adversarial Networks (cGAN) digunakan. cGAN membantu meningkatkan ukuran dataset pelatihan dengan menghasilkan data tambahan. Dalam satu studi, penggunaan cGAN bersama dengan model deep *Transfer Learning* menghasilkan akurasi validasi hingga 94.21% [45]. Ini menunjukkan bahwa teknik ini sangat efektif dalam meningkatkan kinerja model *Deep Learning* dalam kondisi data yang terbatas.

RQ3. Model *Deep Learning* apa yang paling efektif digunakan dalam Diagnosa Awal Penyakit Tuberkulosis?

Berdasarkan hasil analisis yang terdapat pada table 3.3, model yang paling efektif digunakan dalam diagnosa awal penyakit TB adalah:

Tabel 3. 3 Kinerja model *Deep Learning* dalam diagnosa TBC

Model <i>Deep Learning</i>	Akurasi (%)	Keterangan
ResNet50	98.20	Menunjukkan kinerja tertinggi dalam beberapa studi, terutama ketika digabungkan dengan teknik <i>Transfer Learning</i> dan pre-processing hibrida.
DenseNet-169	95.87	Menunjukkan hasil yang sangat baik dengan akurasi validasi tinggi ketika dikombinasikan dengan GAN untuk memperbesar dataset. Memanfaatkan konektivitas padat.
Xception	-	Menunjukkan peningkatan akurasi yang signifikan ketika digunakan bersama dengan teknik GAN dan <i>Transfer Learning</i> . Memanfaatkan depthwise separable convolutions.

ResNet50 adalah salah satu model dengan kinerja tertinggi, mencapai akurasi hingga 98.20% dalam beberapa studi. Keberhasilan ResNet50 semakin meningkat ketika dikombinasikan dengan teknik *Transfer Learning* dan pre-processing hibrida. Model ini unggul karena mampu melatih jaringan yang sangat dalam dengan efisiensi tinggi [38][46].

Sementara itu, DenseNet-169 juga memberikan hasil yang luar biasa dengan akurasi validasi mencapai 95.87%. Kombinasi DenseNet-169 dengan GAN untuk memperbesar dataset terbukti sangat efektif. Kelebihan utama DenseNet-169 adalah konektivitas padat antar lapisan, yang memungkinkan propagasi informasi lebih baik [47][48].

Xception adalah model lain yang menunjukkan peningkatan akurasi yang signifikan. Ketika digunakan bersama dengan teknik GAN dan *Transfer Learning*, Xception mampu meningkatkan efisiensi dan kinerja model. Hal ini dimungkinkan berkat penggunaan depthwise separable convolutions yang inovatif [31].

Dengan integrasi berbagai model ini, kita dapat melihat bagaimana pendekatan yang berbeda saling melengkapi untuk memberikan akurasi dan efisiensi yang lebih baik dalam diagnosa dini Tuberkulosis.

3.1 Diskusi

Hasil penelitian ini menunjukkan bahwa *Deep Learning* memiliki potensi besar dalam diagnosa awal penyakit TB. Metode CNN, terutama ketika dikombinasikan dengan *Transfer Learning* dan teknik GAN, menunjukkan hasil yang sangat baik dalam mendeteksi TB dari gambar X-ray dada. ResNet50 muncul sebagai model yang paling efektif, diikuti oleh DenseNet-169 dan Xception.

3.2 Kekuatan dan Kelemahan Metode yang Digunakan

Deep Learning memiliki kekuatan yang signifikan dalam mengolah dan menganalisis data medis dengan cepat dan akurat. Secara metodologis, deteksi TB dilakukan dengan mengelompokkan gambar CXR ke dalam wilayah paru-paru menggunakan *Deep Learning* (DL), khususnya convolutional NNs (CNNs), bersama dengan beberapa teknik pemrosesan gambar dan algoritma pada tahap selanjutnya [49]. Teknik ini dapat membantu tenaga medis dalam membuat diagnosis yang lebih tepat, berkat kemampuannya mengenali pola-pola kompleks dalam data medis. Misalnya, teknik seperti *Transfer Learning* memungkinkan penggunaan dataset yang lebih kecil dan tidak seimbang dengan hasil yang tetap akurat. Selain itu, *Generative Adversarial Networks* (GAN) dapat meningkatkan ukuran dan kualitas dataset pelatihan, sehingga model *Deep Learning* dapat dilatih lebih efektif meskipun dengan data yang terbatas. Namun, di balik keunggulannya, metode *Deep Learning* juga menghadapi beberapa kelemahan. Salah satu tantangan utama adalah interpretabilitas dan transparansi hasil model. Banyak metode *Deep Learning* dianggap sebagai "black box," yang membuat sulit untuk memahami bagaimana model membuat keputusan tertentu. Selain itu, model *Deep Learning* memerlukan data pelatihan yang berkualitas tinggi dan anotasi yang akurat untuk mencapai hasil yang optimal. Ketidakakuratan atau

kurangnya anotasi dalam data pelatihan dapat mengurangi efektivitas model dan menyebabkan hasil yang kurang andal. kelemahan semua metode pembelajaran mendalam adalah kurangnya transparansi dan kemampuan interpretasi (misalnya, tidak mungkin menentukan fitur pencitraan apa yang digunakan untuk menentukan keluaran) [50].

Dengan demikian, meskipun *Deep Learning* menawarkan banyak manfaat dalam diagnosa medis, penting untuk terus mengembangkan teknik yang meningkatkan interpretabilitas dan memastikan kualitas data pelatihan untuk mengoptimalkan hasil yang diperoleh.

3.3 Implikasi Klinis

Pemanfaatan model *Deep Learning* dalam diagnosa Tuberkulosis (TBC) memiliki potensi besar untuk mengurangi waktu diagnosis dan meningkatkan akurasi, terutama di daerah yang memiliki akses terbatas ke tenaga medis yang berpengalaman. Dengan kemampuan untuk menganalisis data medis dengan cepat dan mendeteksi pola-pola yang mungkin terlewatkan oleh manusia, model-model ini dapat memberikan hasil yang lebih cepat dan tepat, yang sangat penting dalam pengelolaan TBC yang efektif.

Lebih lanjut, model AI ini dapat digunakan sebagai alat bantu dalam mendukung keputusan klinis. Mereka mampu memberikan second opinion yang berharga dalam proses diagnosa, membantu dokter dalam membuat keputusan yang lebih informatif. Misalnya, ketika seorang dokter menerima hasil dari model AI, mereka dapat membandingkannya dengan penilaian mereka sendiri, yang pada akhirnya meningkatkan kepercayaan dan ketepatan diagnosis.

Dengan demikian, integrasi model *Deep Learning* dalam diagnosa TBC tidak hanya mempercepat proses diagnosis tetapi juga menyediakan dukungan yang signifikan untuk tenaga medis, khususnya di daerah dengan sumber daya terbatas.

3.4 Arah Penelitian Masa Depan

Meskipun model *Deep Learning* telah menunjukkan potensi besar dalam diagnosa medis, masih ada beberapa tantangan yang perlu diatasi melalui penelitian lebih lanjut. Salah satu aspek penting adalah meningkatkan interpretabilitas model *Deep Learning*. Segmentasi merupakan langkah penting untuk mengurangi kemungkinan kebocoran data dan memaksa arsitektur klasifikasi untuk fokus hanya pada area penting dan membantu meningkatkan akurasi klasifikasi [51]. Saat ini, banyak model berfungsi sebagai "black box," sehingga sulit untuk memahami bagaimana mereka mencapai keputusan tertentu. Meningkatkan interpretabilitas akan membantu tenaga medis lebih percaya dan memahami hasil yang diberikan oleh model ini.

Selain itu, masalah overfitting juga menjadi perhatian. Model yang terlalu disesuaikan dengan data pelatihan dapat memiliki performa yang buruk saat diterapkan pada data baru. Untuk mengatasi hal ini, pengembangan dataset yang lebih besar dan lebih representatif dari populasi yang berbeda sangat diperlukan. Dataset yang beragam dan mencakup berbagai karakteristik populasi akan membantu meningkatkan generalisasi model, membuatnya lebih andal dan efektif dalam berbagai situasi klinis.

Lebih jauh lagi, integrasi teknik AI dengan sistem kesehatan yang ada adalah langkah penting untuk menciptakan alat diagnostik yang lebih komprehensif dan mudah diakses. Dengan menggabungkan kemampuan AI dalam analisis data dengan infrastruktur kesehatan yang sudah ada, kita dapat menghasilkan alat yang tidak hanya canggih tetapi juga praktis dan dapat digunakan oleh berbagai fasilitas kesehatan, termasuk di daerah dengan sumber daya terbatas.

Dengan fokus pada penelitian lebih lanjut dan pengembangan, masa depan penggunaan *Deep Learning* dalam diagnosa medis terlihat menjanjikan, menawarkan solusi yang lebih akurat dan efisien untuk tantangan kesehatan global.

4. KESIMPULAN

Kesimpulan dari penelitian ini menunjukkan bahwa *Deep Learning* memiliki potensi besar dalam diagnosa awal penyakit Tuberkulosis (TB). Melalui analisis terhadap 50 artikel ilmiah, ditemukan bahwa berbagai metode *Deep Learning*, terutama *Convolutional Neural Networks* (CNNs) dan *Transfer Learning*, dapat digunakan secara efektif untuk mendeteksi TB dari gambar X-ray dada. Metode CNN, seperti ResNet, VGG, dan DenseNet, serta teknik *Generative Adversarial Networks* (GANs) untuk mengatasi masalah ketidakseimbangan data, menunjukkan hasil yang sangat baik dalam meningkatkan akurasi diagnosis.

Algoritme pembelajaran mesin dan pembelajaran mendalam telah dikembangkan untuk meningkatkan alur kerja di bidang radiologi atau untuk membantu ahli radiologi dengan mengotomatiskan tugas-tugas seperti deteksi lesi atau kuantifikasi pencitraan medis [52]. Arsitektur jaringan saraf mendalam yang telah dikembangkan atau disesuaikan khusus untuk diagnosa TB, seperti ResNet50, DenseNet-169, dan Xception, menunjukkan performa yang unggul dalam mendeteksi TB pada tahap awal. ResNet50, khususnya, muncul

sebagai model yang paling efektif dengan akurasi tertinggi yang dicapai dalam berbagai studi. Model ini, ketika dikombinasikan dengan teknik *Transfer Learning* dan pre-processing hibrida, mampu memberikan hasil diagnosis yang cepat, akurat, dan dapat diandalkan.

Namun, meskipun hasil ini menjanjikan, ada beberapa tantangan yang perlu diatasi. Beberapa metode masih menghadapi masalah interpretabilitas dan transparansi hasil model, yang penting untuk aplikasi klinis. Selain itu, model memerlukan data pelatihan yang berkualitas tinggi dan anotasi yang akurat untuk mencapai kinerja terbaik.

Penelitian ini juga menyoroti pentingnya pengembangan dataset yang lebih besar dan lebih representatif dari populasi yang berbeda untuk meningkatkan generalisasi model. Integrasi teknik AI dengan sistem kesehatan yang ada juga diperlukan untuk menciptakan alat diagnostik yang lebih komprehensif dan mudah diakses. Dengan peningkatan lebih lanjut dan validasi klinis, *Deep Learning* dapat menjadi alat yang sangat efektif dalam mendeteksi TB, membantu mengurangi waktu diagnosis dan meningkatkan akurasi, terutama di daerah dengan akses terbatas ke tenaga medis yang berpengalaman.

Secara keseluruhan, penelitian ini memberikan gambaran komprehensif tentang state-of-the-art dalam diagnosa awal TB menggunakan *Deep Learning*, menunjukkan potensi besar teknologi ini untuk diimplementasikan secara luas dalam praktik klinis dengan pengembangan dan validasi lebih lanjut.

DAFTAR PUSTAKA

- [1] V. Acharya *et al.*, "AI-Assisted Tuberculosis Detection and Classification from Chest X-Rays Using a Deep Learning Normalization-Free Network Model," *Comput. Intell. Neurosci.*, vol. 2022, 2022, doi: 10.1155/2022/2399428.
- [2] E. Tasci, C. Uluturk, and A. Ugur, "A voting-based ensemble deep learning method focusing on image augmentation and preprocessing variations for tuberculosis detection," *Neural Comput. Appl.*, vol. 33, no. 22, pp. 15541–15555, 2021, doi: 10.1007/s00521-021-06177-2.
- [3] K. Y. Win, N. Maneerat, K. Hamamoto, and S. Sreng, "Hybrid learning of hand-crafted and deep-activated features using particle swarm optimization and optimized support vector machine for tuberculosis screening," *Appl. Sci.*, vol. 10, no. 17, pp. 1–22, 2020, doi: 10.3390/AP10175749.
- [4] N. Ullah, M. Marzougui, I. Ahmad, and S. A. Chelloug, "DeepLungNet: An Effective DL-Based Approach for Lung Disease Classification Using CRIs," *Electron.*, vol. 12, no. 8, 2023, doi: 10.3390/electronics12081860.
- [5] Y. Yang *et al.*, "A prospective multicenter clinical research study validating the effectiveness and safety of a chest X-ray-based pulmonary tuberculosis screening software JF CXR-1 built on a convolutional neural network algorithm," *Front. Med.*, vol. 10, 2023, doi: 10.3389/fmed.2023.1195451.
- [6] A. Naidu, S. S. Nayak, S. Lulu S, and V. Sundararajan, "Advances in computational frameworks in the fight against TB: The way forward," *Front. Pharmacol.*, vol. 14, no. April, pp. 1–24, 2023, doi: 10.3389/fphar.2023.1152915.
- [7] M. Pahar, M. Kloppe, B. Reeve, R. Warren, G. Theron, and T. Niesler, "Automatic cough classification for tuberculosis screening in a real-world environment," *Physiol. Meas.*, vol. 42, no. 10, 2021, doi: 10.1088/1361-6579/ac2fb8.
- [8] T. Rahman *et al.*, "TB-CXRNet: Tuberculosis and Drug-Resistant Tuberculosis Detection Technique Using Chest X-ray Images," *Cognit. Comput.*, pp. 1393–1412, 2024, doi: 10.1007/s12559-024-10259-3.
- [9] T. Mehta and N. Mehendale, "Classification of X-ray images into COVID-19, pneumonia, and TB using cGAN and fine-tuned deep transfer learning models," *Res. Biomed. Eng.*, vol. 37, no. 4, pp. 803–813, 2021, doi: 10.1007/s42600-021-00174-z.
- [10] T. Khatibi, A. Shahsavari, and A. Farahani, "Proposing a novel multi-instance learning model for tuberculosis recognition from chest X-ray images based on CNNs, complex networks and stacked ensemble," *Phys. Eng. Sci. Med.*, vol. 44, no. 1, pp. 291–311, 2021, doi: 10.1007/s13246-021-00980-w.
- [11] T. Rahman *et al.*, "Reliable tuberculosis detection using chest X-ray with deep learning, segmentation and visualization," *IEEE Access*, vol. 8, pp. 191586–191601, 2020, doi: 10.1109/ACCESS.2020.3031384.
- [12] C. Dasanayaka and M. B. Dissanayake, "Deep Learning Methods for Screening Pulmonary Tuberculosis Using Chest X-rays," *Comput. Methods Biomech. Biomed. Eng. Imaging Vis.*, vol. 9, no. 1, pp. 39–49, 2021, doi: 10.1080/21681163.2020.1808532.
- [13] M. Nijati *et al.*, "Artificial Intelligence Assisting the Early Detection of Active Pulmonary Tuberculosis From Chest X-Rays: A Population-Based Study," *Front. Mol. Biosci.*, vol. 9, no. April, pp. 1–9, 2022, doi: 10.3389/fmolb.2022.874475.
- [14] G. M. M. Alshmrani, Q. Ni, R. Jiang, H. Pervaiz, and N. M. Elshennawy, "A deep learning architecture for multi-class lung diseases classification using chest X-ray (CXR) images," *Alexandria Eng. J.*, vol. 64,

- pp. 923–935, 2023, doi: 10.1016/j.aej.2022.10.053.
- [15] T. Ozturk, M. Talo, E. A. Yildirim, U. B. Baloglu, O. Yildirim, and U. Rajendra Acharya, “Automated detection of COVID-19 cases using deep neural networks with X-ray images,” *Comput. Biol. Med.*, vol. 121, no. April, p. 103792, 2020, doi: 10.1016/j.compbiomed.2020.103792.
- [16] X. Li, Y. Zhou, P. Du, G. Lang, M. Xu, and W. Wu, “A deep learning system that generates quantitative CT reports for diagnosing pulmonary Tuberculosis,” *Appl. Intell.*, vol. 51, no. 6, pp. 4082–4093, 2021, doi: 10.1007/s10489-020-02051-1.
- [17] R. Guo, K. Passi, and C. K. Jain, “Tuberculosis Diagnostics and Localization in Chest X-Rays via Deep Learning Models,” *Front. Artif. Intell.*, vol. 3, no. October, pp. 1–17, 2020, doi: 10.3389/frai.2020.583427.
- [18] M. A. Elashmawy, I. Elamvazuthi, L. I. Izhar, S. Paramasivam, and S. Su, “Detection of Tuberculosis Based on Hybridized Pre-Processing Deep Learning Method,” *Int. J. Adv. Comput. Sci. Appl.*, vol. 14, no. 8, pp. 69–76, 2023, doi: 10.14569/IJACSA.2023.0140808.
- [19] S. H. Yoo *et al.*, “Deep Learning-Based Decision-Tree Classifier for COVID-19 Diagnosis From Chest X-ray Imaging,” *Front. Med.*, vol. 7, no. July, pp. 1–8, 2020, doi: 10.3389/fmed.2020.00427.
- [20] M. K. Puttagunta and S. Ravi, “Deteksi Tuberkulosis berdasarkan metode berbasis Deep Learning,” *J. Phys. Conf. Ser.*, vol. 1767, no. 1, 2021, doi: 10.1088/1742-6596/1767/1/012004.
- [21] S. Natarajan *et al.*, “Early diagnosis and meta-agnostic model visualization of tuberculosis based on radiography images,” *Sci. Rep.*, vol. 13, no. 1, pp. 1–13, 2023, doi: 10.1038/s41598-023-49195-x.
- [22] Z. Zhou, M. M. R. Siddiquee, N. Tajbakhsh, and J. Liang, “UNet++: Redesigning Skip Connections to Exploit Multiscale Features in Image Segmentation,” *IEEE Trans. Med. Imaging*, vol. 39, no. 6, pp. 1856–1867, 2020, doi: 10.1109/TMI.2019.2959609.
- [23] M. Jasmine Pemeena Priyadarsini *et al.*, “Lung Diseases Detection Using Various Deep Learning Algorithms,” *J. Healthc. Eng.*, vol. 2023, 2023, doi: 10.1155/2023/3563696.
- [24] R. I. Chang, Y. H. Chiu, and J. W. Lin, “Two-stage classification of tuberculosis culture diagnosis using convolutional neural network with transfer learning,” *J. Supercomput.*, vol. 76, no. 11, pp. 8641–8656, 2020, doi: 10.1007/s11227-020-03152-x.
- [25] L. Alzubaidi *et al.*, *Review of deep learning: concepts, CNN architectures, challenges, applications, future directions*, vol. 8, no. 1. Springer International Publishing, 2021. doi: 10.1186/s40537-021-00444-8.
- [26] E. Kotei and R. Thirunavukarasu, “Ensemble Technique Coupled with Deep Transfer Learning Framework for Automatic Detection of Tuberculosis from Chest X-ray Radiographs,” *Healthc.*, vol. 10, no. 11, 2022, doi: 10.3390/healthcare10112335.
- [27] D. A. Moses, “Deep learning applied to automatic disease detection using chest X-rays,” *J. Med. Imaging Radiat. Oncol.*, vol. 65, no. 5, pp. 498–517, 2021, doi: 10.1111/1754-9485.13273.
- [28] L. Liu *et al.*, “Deep Learning for Generic Object Detection: A Survey,” *Int. J. Comput. Vis.*, vol. 128, no. 2, pp. 261–318, 2020, doi: 10.1007/s11263-019-01247-4.
- [29] M. Owais, M. Arsalan, T. Mahmood, Y. H. Kim, and K. R. Park, “Comprehensive computer-aided decision support framework to diagnose tuberculosis from chest X-Ray images: Data mining study,” *JMIR Med. Informatics*, vol. 8, no. 12, pp. 1–23, 2020, doi: 10.2196/21790.
- [30] G. Deepak and C. Muralidharan, “Improved Tuberculosis Detection through Deep Learning,” *Int. Res. J. Multidiscip. Scope*, vol. 5, no. 2, pp. 540–548, 2024, doi: 10.47857/irjms.2024.v05i02.0563.
- [31] Y. Liu, Y. H. Wu, Y. Ban, H. Wang, and M. M. Cheng, “Rethinking computer-aided tuberculosis diagnosis,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, pp. 2643–2652, 2020, doi: 10.1109/CVPR42600.2020.00272.
- [32] M. K. Puttagunta and S. Ravi, “Detection of Tuberculosis based on Deep Learning based methods,” *J. Phys. Conf. Ser.*, vol. 1767, no. 1, 2021, doi: 10.1088/1742-6596/1767/1/012004.
- [33] A. Khan, A. Sohail, U. Zahoor, and A. S. Qureshi, *A survey of the recent architectures of deep convolutional neural networks*, vol. 53, no. 8. Springer Netherlands, 2020. doi: 10.1007/s10462-020-09825-6.
- [34] Q. Wang, B. Wu, P. Zhu, P. Li, W. Zuo, and Q. Hu, “ECA-Net: Perhatian Saluran yang Efisien untuk Jaringan Neural Konvolusional Dalam,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, pp. 11531–11539, 2020, doi: 10.1109/CVPR42600.2020.01155.
- [35] A. F. M. Saif, T. Imtiaz, C. Shahnaz, W. P. Zhu, and M. O. Ahmad, “Exploiting cascaded ensemble of features for the detection of tuberculosis using chest radiographs,” *IEEE Access*, vol. 9, pp. 112388–112399, 2021, doi: 10.1109/ACCESS.2021.3102077.
- [36] K. Santosh, S. Allu, S. Rajaraman, and S. Antani, “Advances in Deep Learning for Tuberculosis Screening using Chest X-rays: The Last 5 Years Review,” *J. Med. Syst.*, vol. 46, no. 11, 2022, doi: 10.1007/s10916-022-01870-8.
- [37] J. Zhou *et al.*, “Graph neural networks: A review of methods and applications,” *AI Open*, vol. 1, no. September 2020, pp. 57–81, 2020, doi: 10.1016/j.aiopen.2021.01.001.

-
-
- [38] M. Ayaz, F. Shaukat, and G. Raja, "Ensemble learning based automatic detection of tuberculosis in chest X-ray images using hybrid feature descriptors," *Phys. Eng. Sci. Med.*, vol. 44, no. 1, pp. 183–194, 2021, doi: 10.1007/s13246-020-00966-0.
- [39] M. Mamalakos *et al.*, "DenResCov-19: A deep transfer learning network for robust automatic classification of COVID-19, pneumonia, and tuberculosis from X-rays," *Comput. Med. Imaging Graph.*, vol. 94, no. April, p. 102008, 2021, doi: 10.1016/j.compmedimag.2021.102008.
- [40] Y. Xu, H. K. Lam, and G. Jia, "MANet: A two-stage deep learning method for classification of COVID-19 from Chest X-ray images," *Neurocomputing*, vol. 443, pp. 96–105, 2021, doi: 10.1016/j.neucom.2021.03.034.
- [41] M. Zachariou, O. Arandjelović, and D. J. Sloan, "Automated Methods for Tuberculosis Detection/Diagnosis: A Literature Review," *BioMedInformatics*, vol. 3, no. 3, pp. 724–751, 2023, doi: 10.3390/biomedinformatics3030047.
- [42] M. Nijati *et al.*, "Deep learning on longitudinal CT scans: automated prediction of treatment outcomes in hospitalized tuberculosis patients," *iScience*, vol. 26, no. 11, p. 108326, 2023, doi: 10.1016/j.isci.2023.108326.
- [43] S. H. Yoo *et al.*, "Pohon Keputusan Berbasis Pembelajaran Mendalam Pengklasifikasi untuk Diagnosis COVID-19 Dari Pencitraan Rontgen Dada," *Front. Med.*, vol. 7, pp. 1–8, 2020, doi: 10.3389/fmed.2020.00427.
- [44] V. Ravi, V. Acharya, and M. Alazab, "A multichannel EfficientNet deep learning-based stacking ensemble approach for lung disease detection using chest X-ray images," *Cluster Comput.*, vol. 26, no. 2, pp. 1181–1203, 2023, doi: 10.1007/s10586-022-03664-6.
- [45] I. D. Apostolopoulos and T. A. Mpesiana, "Covid-19: automatic detection from X-ray images utilizing transfer learning with convolutional neural networks," *Phys. Eng. Sci. Med.*, vol. 43, no. 2, pp. 635–640, 2020, doi: 10.1007/s13246-020-00865-4.
- [46] C. Ying *et al.*, "T-SPOT with CT image analysis based on deep learning for early differential diagnosis of nontuberculous mycobacteria pulmonary disease and pulmonary tuberculosis," *Int. J. Infect. Dis.*, vol. 125, pp. 42–50, 2022, doi: 10.1016/j.ijid.2022.09.031.
- [47] Y. Yang *et al.*, "Sebuah studi penelitian klinis prospektif multisenter yang memvalidasi efektivitas dan keamanan dada Perangkat lunak skrining tuberkulosis paru berbasis sinar X JF CXR-1 dibangun di atas algoritma jaringan saraf konvolusional," *Front. Med.*, vol. 10, pp. 1–9, 2023, doi: 10.3389/fmed.2023.1195451.
- [48] M. Kavitha, K. Vidhya, S. Sreeja, G. Roopashri, and P. Muhil, "Automated lung disease detection, classification and prediction using RNN framework," *E3S Web Conf.*, vol. 491, pp. 1–9, 2024, doi: 10.1051/e3sconf/202449103015.
- [49] S. I. Nafisah and G. Muhammad, "Tuberculosis detection in chest radiograph using convolutional neural network architecture and explainable artificial intelligence," *Neural Comput. Appl.*, vol. 36, no. 1, pp. 111–131, 2024, doi: 10.1007/s00521-022-07258-6.
- [50] L. Li *et al.*, "Using Artificial Intelligence to Detect COVID-19 and Community-acquired Pneumonia Based on Pulmonary CT: Evaluation of the Diagnostic Accuracy," *Radiology*, vol. 296, no. 2, pp. E65–E71, 2020, doi: 10.1148/radiol.20200905.
- [51] S. Gite, A. Mishra, and K. Kotecha, "Enhanced lung image segmentation using deep learning," *Neural Comput. Appl.*, vol. 35, no. 31, pp. 22839–22853, 2023, doi: 10.1007/s00521-021-06719-8.
- [52] J. Naidoo, S. C. Shelmerdine, C. F. Ugas-Charcape, and A. S. Sodhi, "Artificial Intelligence in Paediatric Tuberculosis," *Pediatr. Radiol.*, vol. 53, no. 9, pp. 1733–1745, 2023, doi: 10.1007/s00247-023-05606-9.