



Pengembangan Model *Hybrid* untuk Identifikasi Tuberkulosis Pada Gambar Rontgen Dada

Ridwan Mahenra

Informatika, Universitas Teknokrat Indonesia, Indonesia

ridwanmahrenra@teknokrat.ac.id

Abstrak: Tuberkulosis (TB), penyakit menular parah yang berdampak pada jutaan orang di seluruh dunia, umumnya didiagnosis menggunakan rontgen dada. Untuk memastikan diagnosis yang akurat, terutama pada tahap awal, para profesional di bidang kesehatan mengandalkan dukungan teknologi canggih. Berbeda dengan model-model yang ada yang berfokus pada deteksi TB pada gambar sinar-X, penelitian ini bertujuan untuk mengklasifikasikan gambar yang berhubungan dengan TB guna memfasilitasi pemilihan metode yang tepat untuk deteksi TB yang akurat. Pendekatan yang diusulkan menggabungkan kemampuan arsitektur VGG16 dengan jaringan syaraf tiruan (CNN) untuk klasifikasi gambar. VGG16 dimodifikasi untuk ekstraksi fitur guna mengidentifikasi tanda-tanda TB pada gambar sinar-X, sementara CNN digunakan untuk mengkategorikan gambar berdasarkan indikasi TB. Evaluasi dilakukan dengan menggunakan dataset standar, yang menunjukkan bahwa metode yang diusulkan mencapai akurasi 98,2% untuk kelas normal dan 98,4% untuk kelas TB, dengan recall dan presisi yang sangat baik, mengungguli metode yang ada saat ini, seperti CNN berbasis hibrida, MobileNet, serta metode berbasis HOG dan LBP.

Kata Kunci: Tuberkulosis; Model VGG-16; Pembelajaran mendalam; Jaringan Syaraf Tiruan; Sinar-X.

Abstract: Tuberculosis (TB), a severe infectious disease that affects millions of people worldwide, is commonly diagnosed using chest X-rays. To ensure an accurate diagnosis, especially in the early stages, healthcare professionals rely on advanced technological support. In contrast to existing models that focus on TB detection in X-ray images, this study aims to classify TB-related images to facilitate the selection of appropriate methods for accurate TB detection. The proposed approach combines the architectural capabilities of VGG16 with an artificial neural network (CNN) for image classification. VGG16 is modified for feature extraction to identify signs of TB in X-ray images, while CNN is used to categorize images based on TB indications. Evaluation was conducted using a standard dataset, which showed that the proposed method achieved an accuracy of 98.2% for the normal class and 98.4% for the TB class, with excellent recall and



precision, outperforming existing methods, such as hybrid-based CNN, MobileNet, as well as HOG and LBP-based methods.

Keywords: Tuberculosis; VGG-16 Model; Deep-Learning; Convolutional Neural Network; X-ray.

1. PENDAHULUAN

Studi terbaru tentang topik yang berhubungan dengan kesehatan telah menyoroti pentingnya diagnosis dini dan deteksi gejala dalam mengendalikan penyebaran penyakit menular dan mencegah wabah [1-2]. Tuberkulosis (TB), salah satu masalah kesehatan global yang utama, masih menjadi salah satu penyebab utama kematian di seluruh dunia [3]. Penyakit ini terutama tersebar luas di negara-negara berpenghasilan rendah dan menengah, di mana faktor-faktor seperti kemiskinan, kepadatan penduduk, dan sumber daya perawatan kesehatan yang terbatas memperburuk dampak penyakit ini. TBC disebabkan oleh *Mycobacterium tuberculosis*, yang terutama menyerang paru-paru tetapi juga berpotensi memengaruhi organ lain, sehingga membuat diagnosis dan pengobatannya menjadi menantang [3].

Alat diagnostik utama untuk TB adalah rontgen dada, yang memberikan gambaran visual paru-paru kepada ahli radiologi, yang membantu mereka mengidentifikasi tanda-tanda khas TB, seperti rongga, nodul, dan pola infiltrasi. Namun, menginterpretasikan rontgen dada adalah tugas yang kompleks yang membutuhkan pengetahuan dan keahlian khusus. Proses ini sering kali bersifat subjektif, sehingga menimbulkan variabilitas dalam hasil diagnostik. Selama bertahun-tahun, beberapa metode telah dikembangkan untuk membantu deteksi dan klasifikasi TB [4]. Sebagian besar metode ini berfokus pada identifikasi daerah yang menarik yang mengindikasikan gejala terkait TB dalam gambar untuk klasifikasi. Namun, metode-metode ini dapat rentan terhadap kebisingan dan kecacauan latar belakang, sehingga menjadi kurang efektif ketika citra mengandung elemen latar belakang yang tidak terkait TB atau citra normal yang terdegradasi. Selain itu, area yang terkena dampak pada citra TB bisa jadi tidak kentara, sehingga menyulitkan metode-metode mutakhir untuk secara akurat mendeteksi dan mengklasifikasikan penyakit ini.

Meskipun penelitian sebelumnya telah mengusulkan berbagai metode untuk deteksi dan klasifikasi TB [5, 6], terdapat beberapa kesenjangan yang belum sepenuhnya teratas. Pertama, metode yang ada sering kali gagal membedakan secara akurat antara citra normal dan citra TB, terutama ketika daerah yang terkena dampak tidak jelas atau ketika citra mengandung kebisingan latar belakang. Kedua, sebagian besar pendekatan yang ada memerlukan sumber daya komputasi yang signifikan dan kompleksitas algoritmik yang tinggi, yang membatasi penerapannya di daerah dengan sumber daya terbatas. Ketiga, belum ada metode yang secara efektif menggabungkan ekstraksi fitur yang kuat dengan model klasifikasi yang sederhana dan efisien untuk meningkatkan akurasi deteksi TB.

Mendeteksi TB secara akurat merupakan hal yang kompleks dan menantang. Hal ini terlihat dari contoh gambar yang ditunjukkan pada Gambar 1(a) dan (b), di mana tidak mudah bagi mata untuk mengidentifikasi gambar pada (a) adalah gambar normal dan gambar pada (b) adalah gambar TB. Hal ini divalidasi lebih lanjut dari hasil metode yang sudah ada [5, 6] yang salah mengklasifikasikan citra normal sebagai citra TB dan sebaliknya seperti yang ditunjukkan pada Gbr. 1. Untuk mengurangi kompleksitas deteksi TB, perlu untuk mengklasifikasikan citra yang terkena TB dari citra normal (bebas TB) sehingga seseorang dapat memilih metode yang paling baik untuk mendeteksi TB meskipun daerah vital tidak terlihat [7, 8]. Ide ini membantu kita untuk menggunakan sumber daya yang tersedia secara efektif daripada mengembangkan metode baru. Oleh karena itu, penelitian ini berfokus pada pengembangan metode baru untuk klasifikasi citra TB. Oleh karena itu, penelitian ini bertujuan untuk mengatasi kesenjangan tersebut dengan

mengusulkan metode baru yang menggabungkan ekstraksi fitur menggunakan VGG16 dengan jaringan saraf tiruan sederhana untuk klasifikasi citra TB. VGG16 dipilih karena kemampuannya yang terbukti dalam mengekstrak fitur yang efektif untuk klasifikasi [9], sementara jaringan saraf tiruan yang diusulkan dirancang untuk meningkatkan akurasi klasifikasi dengan kompleksitas yang lebih rendah. Oleh karena itu, kontribusi utama dari penelitian ini adalah sebagai berikut:

- Mengadaptasi VGG16 untuk ekstraksi fitur yang berbeda untuk mengklasifikasikan citra TB dari citra normal.
- Mengusulkan CNN untuk keberhasilan klasifikasi gambar TB dari gambar normal
- Menggabungkan dua model sederhana dengan cara baru untuk mencapai hasil klasifikasi terbaik.



(a) Gambar Normal



(b) Gambar Tuberkulosis

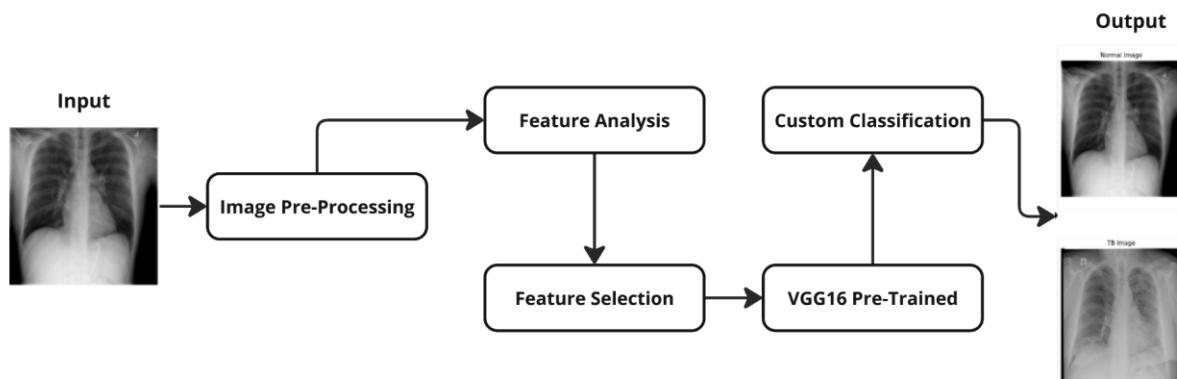
Gambar 1. Contoh citra normal dan Tuberkulosis (TB). Metode yang diusulkan berhasil mengklasifikasikan citra normal dan TB sementara metode yang ada [5, 6] salah mengklasifikasikan.

Struktur penelitian ini adalah sebagai berikut: Bagian 2 menjelaskan model yang diusulkan, termasuk arsitektur dan alasan di balik desainnya. Bagian 3 menguraikan pengaturan eksperimental, pemrosesan data, dan hasil, yang menunjukkan kinerja model.

2. METODE PENELITIAN

Metodologi yang digunakan dalam penelitian ini adalah kombinasi proses dan teknik ilmiah yang dibuat dengan cermat yang bertujuan untuk menciptakan model pembelajaran mendalam yang canggih, andal, dan efisien untuk mendeteksi Tuberkulosis (TBC) dari gambar rontgen dada. Bagian ini merinci proses lengkap untuk mengklasifikasikan gambar TB versus gambar normal. Gambar 2 mengilustrasikan diagram arsitektur dari model yang diusulkan. Pada Gambar 2, input dimulai dari direktori dan dilanjutkan dengan langkah-langkah preprocessing seperti pengubahan ukuran, augmentasi, normalisasi, dan

penskalaan ulang. Akhirnya, analisis fitur diterapkan, dan kemudian dilanjutkan dengan pemilihan fitur. Setelah fitur dipilih, pekerjaan yang diusulkan menggunakan model VGG-16 yang telah dilatih sebelumnya di mana ia melewati beberapa lapisan konvolusi untuk ekstraksi fitur dan setelah selesai, ia masuk ke lapisan CNN di mana blok konvolusi mengekstraksi fitur dan akhirnya pengklasifikasi bersama dengan aktivasi softmax memisahkannya menjadi output yang merupakan Normal atau TB.



Gambar 1. Diagram blok yang diusulkan

2.1 Persiapan Data

Dataset yang digunakan dalam penelitian ini terdiri dari gambar rontgen dada yang dikumpulkan dari National Institutes of Health (NIH) Chest X-ray Dataset dan Kaggle Tuberculosis (TB) Chest X-ray Dataset. Untuk memastikan generalisasi model, dataset dibagi menjadi tiga subset: training (70%), validation (15%), dan testing (15%). Dataset ini dipilih karena ketersediaannya yang terbuka untuk penelitian dan mencakup variasi gambar rontgen dada yang cukup untuk analisis mendalam.

2.2 Image Pre-Processing

Sebelum memasukkan gambar ke dalam model, dilakukan beberapa langkah preprocessing untuk meningkatkan kualitas data dan memastikan konsistensi input. Langkah-langkah preprocessing meliputi:

- 1) Pengubahan Ukuran: Semua gambar diubah ukurannya menjadi 224x224 piksel untuk menyesuaikan dengan input arsitektur VGG16.
- 2) Augmentasi Data: Untuk meningkatkan variasi data dan mencegah overfitting, augmentasi data dilakukan dengan teknik seperti rotasi (hingga 20 derajat), flipping horizontal, dan zooming (hingga 20%).
- 3) Normalisasi: Nilai piksel gambar dinormalisasi ke rentang [0, 1] dengan membagi setiap nilai piksel dengan 255.
- 4) Penskalaan Ulang: Gambar diubah ke dalam format tensor yang kompatibel dengan framework TensorFlow/Keras.

2.3 Arsitektur Model

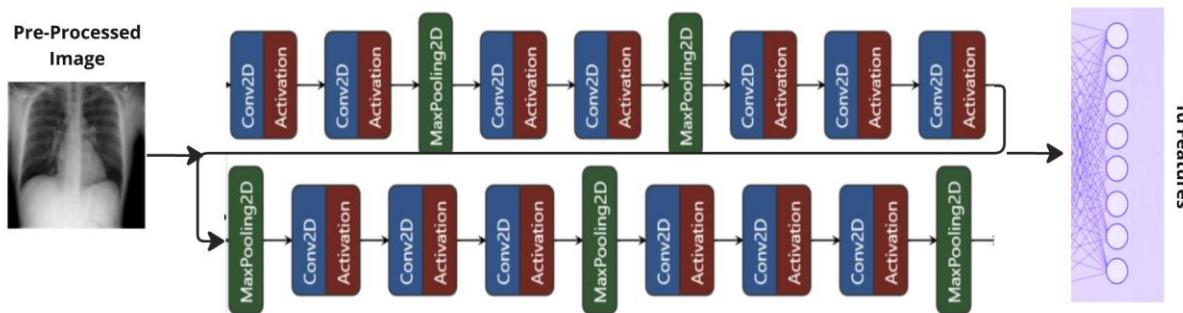
2.3.1 VGG16 untuk Ekstraksi Fitur

Seperti yang telah dibahas sebelumnya, motivasi untuk mengadaptasi arsitektur VGG16 adalah karena keampuhannya yang telah terbukti dalam klasifikasi dan pengenalan gambar. Desainnya dicirikan oleh kesederhanaan dan kedalamannya, yang merupakan kunci untuk menangkap pola yang rumit pada sinar-X dada untuk deteksi TB [31]. Ada arsitektur lain yang terkenal, seperti ResNet, Inception, dan AlexNet. ResNet, yang dikenal karena memecahkan masalah gradien yang hilang, adalah pesaing yang kuat. Namun, koneksi residualnya yang kompleks membuatnya kurang mudah dibandingkan VGG16.

Model awal, dengan jalur konvolusi paralelnya, menawarkan kinerja yang hebat tetapi dengan biaya peningkatan kompleksitas model. AlexNet, meskipun secara historis signifikan, tidak memiliki kedalaman dan kecanggihan VGG16. Arsitektur seragam VGG16, yang terdiri dari blok-blok lapisan konvolusi dan max-pooling yang berulang, menyederhanakan proses ekstraksi fitur. Keseragaman ini memungkinkan jaringan yang dalam yang dapat mempelajari berbagai macam fitur tanpa kerumitan arsitektur model lainnya. Arsitektur model VGG16 dimodifikasi agar sesuai dengan deteksi TB dari sinar-X dada. Berikut adalah analisis terperinci dari setiap jenis lapisan.

Arsitektur VGG16, yang dikembangkan oleh Visual Geometry Group (VGG) di University of Oxford, terdiri dari total 16 lapisan, termasuk 13 lapisan konvolusi dan 3 lapisan yang terhubung penuh, seperti yang digambarkan pada Gambar 2. Lapisan convolutional memiliki ukuran kernel yang konsisten yaitu 3×3 dengan langkah 1, memungkinkan jaringan untuk menangkap hierarki spasial yang terperinci dalam gambar input. Lapisan-lapisan ini diselingi dengan lapisan max-pooling yang menggunakan jendela pooling 2×2 untuk mengurangi dimensi spasial, sehingga mengelola beban komputasi dan mencegah overfitting. Setiap lapisan konvolusi diikuti oleh fungsi aktivasi Rectified Linear Unit (ReLU), yang memperkenalkan non-linearitas dan memungkinkan model untuk mempelajari pola-pola yang kompleks.

Dalam penelitian ini, VGG16 diadaptasi dengan mengecualikan lapisan klasifikasi teratas (menggunakan `include_top = False`), mengubah model menjadi ekstraktor fitur yang kuat. Modifikasi ini menggunakan bobot yang telah dilatih sebelumnya dari dataset ImageNet, yang mencakup beragam fitur gambar, sehingga meningkatkan generalisasi model untuk gambar sinar-X dada. Arsitekturnya dimulai dengan basis VGG16, diikuti oleh lapisan Flatten yang mengubah peta fitur 3D menjadi vektor fitur 1D. Kemudian dilanjutkan dengan lapisan Dense dengan fungsi aktivasi sigmoid, yang disesuaikan untuk tugas klasifikasi biner. Model yang dihasilkan secara efektif membedakan antara normal dan gambar sinar-X yang terkena tuberkulosis, dengan memanfaatkan representasi fitur mendalam yang dipelajari dari korpus ImageNet yang luas, sehingga memastikan kinerja yang kuat dan akurasi diagnostik yang ditingkatkan dalam analisis gambar medis. Gambar 2 mengilustrasikan arsitektur VGG16 yang diadaptasi untuk masalah ini.



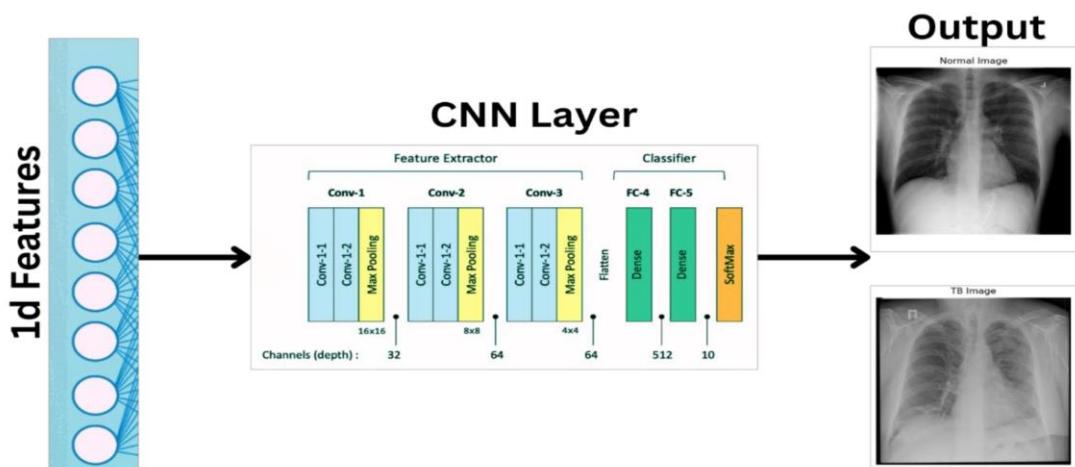
Gambar 2. VGG16 untuk ekstraksi fitur.

2.3.2 Usulan CNN untuk Klasifikasi citra normal dan TB

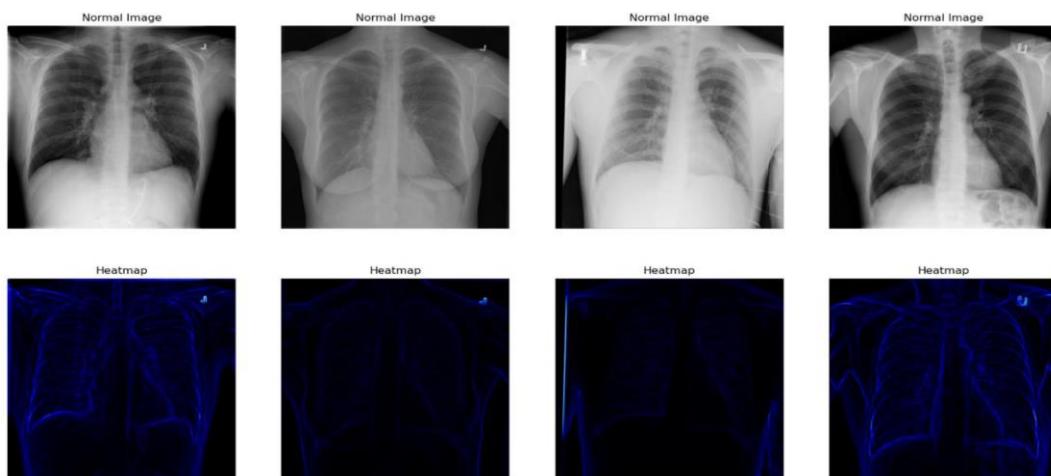
Arsitektur Convolutional Neural Network (CNN) yang digunakan dalam penelitian ini sangat penting untuk menganalisis dan mengkategorikan gambar medis secara kuat, khususnya rontgen dada. CNN dirancang untuk memproses data seperti kisi-kisi, seperti gambar, dengan menggunakan konsep arsitektur utama termasuk bidang reseptif lokal, bobot bersama, dan operasi penyatuhan.

Arsitektur lengkapnya ditunjukkan pada Gambar 3. Arsitektur ini terdiri dari berbagai lapisan: Convolutional Layers, sangat penting untuk mendeteksi pola dan fitur lokal; Fungsi Aktivasi seperti Rectified Linear Unit (ReLU) yang memperkenalkan non-linearitas untuk

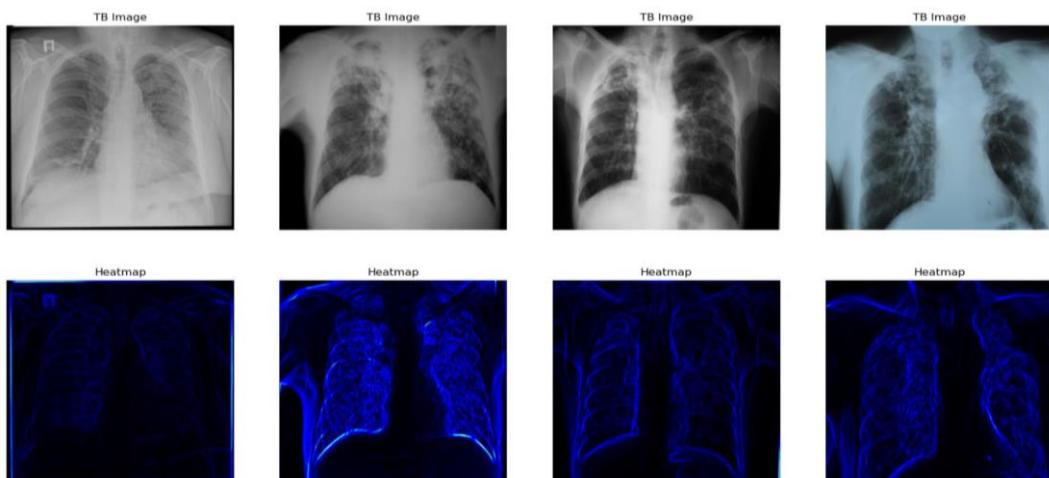
menangkap representasi gambar yang kompleks; Pooling Layers, mengurangi dimensi spasial dan kompleksitas komputasi; dan Fully Connected Layers, melakukan penalaran tingkat tinggi berdasarkan fitur-fitur yang diekstraksi [32]. Menuju klasifikasi, lapisan keluaran akhir dengan fungsi aktivasi sigmoid digunakan, memfasilitasi probabilitas klasifikasi biner untuk membedakan antara kelas normal dan tuberkulosis. Desain hirarkis CNN secara efisien menangkap dan belajar dari sifat hirarkis data visual, membuatnya ideal untuk tugas-tugas seperti analisis citra medis. Dengan memanfaatkan kedalaman CNN dan kemampuan ekstraksi fitur, penelitian ini bertujuan untuk mendapatkan akurasi yang tinggi dalam membedakan antara gambar rontgen dada yang normal dan yang terkena TBC. Gambar 4 menunjukkan Arsitektur CNN yang diadaptasi untuk masalah tersebut.



Gambar 3. Usulan CNN untuk klasifikasi gambar normal dan TB



(a) Gambar normal dan masing-masing heatmaps



(b) Gambar Tuberkulosis dan masing-masing heatmaps

Gambar 4. Peta panas dari masing-masing gambar normal dan TB menunjukkan bahwa fitur yang diusulkan elegan untuk mengklasifikasikan gambar normal dan TB. Struktur yang tidak konsisten dengan kecerahan yang lebih tinggi untuk TB sementara struktur biasa dengan kecerahan rendah untuk gambar normal.

Keefektifan klasifikasi citra TB dan citra normal yang diusulkan ditunjukkan pada Gambar 4. Gambar TB menunjukkan opasitas yang lebih tinggi dan daerah yang lebih terang, terutama menyoroti gigi berlubang, dibandingkan dengan peta panas gambar normal. Pengamatan ini menunjukkan bahwa kombinasi VGG16 dan CNN secara efektif mengekstrak fitur-fitur yang berbeda untuk klasifikasi gambar TB dan normal.

2.4 Pelatihan Model

Model dilatih menggunakan dataset training dengan pengaturan hyperparameter yang telah ditentukan. Optimizer yang digunakan adalah Adam optimizer dengan learning rate sebesar 0.001, dipilih karena kemampuannya dalam menyesuaikan learning rate secara adaptif dan efisiensi komputasinya. Fungsi loss yang digunakan adalah Binary Cross-Entropy, yang sesuai untuk masalah klasifikasi biner seperti dalam penelitian ini. Pelatihan dilakukan dengan batch size 32 untuk menyeimbangkan penggunaan memori dan kecepatan konvergensi model. Proses pelatihan dijalankan selama 50 epoch, dengan mekanisme early stopping yang diaktifkan untuk mencegah overfitting. Early stopping memantau akurasi pada dataset validation, dan jika tidak ada peningkatan signifikan dalam akurasi validation selama 5 epoch berturut-turut, pelatihan akan dihentikan secara otomatis. Metrik evaluasi yang digunakan selama pelatihan dan validasi meliputi akurasi, presisi, recall, dan F1-score, yang memberikan gambaran komprehensif tentang performa model dalam mengklasifikasikan gambar normal dan gambar terindikasi TB.

3. HASIL DAN PEMBAHASAN

Selama tahap eksperimen, penilaian menyeluruh terhadap kinerja model dilakukan dengan menggunakan berbagai metrik, termasuk akurasi, recall, dan presisi. Untuk mengevaluasi metode yang diusulkan dan metode yang sudah ada, penelitian ini menggunakan dataset standar untuk eksperimen.



3.1 Dataset dan Evaluasi

Terdiri dari 4200 gambar rontgen dada, yang dibagi menjadi dua bagian: 3.500 gambar paru-paru yang sehat (normal) dan 700 gambar yang menunjukkan gejala TB. Kriteria pemilihan untuk gambar-gambar ini sangat ketat, memastikan data yang berkualitas tinggi dan relevan secara klinis [33]. Gambar Normal: Gambar-gambar ini dipilih dengan cermat untuk mewakili berbagai kondisi paru-paru yang sehat, yang bersumber dari berbagai institusi kesehatan dan database publik. Kriteria inklusi memastikan representasi dari berbagai kondisi paru-paru yang tampak normal tetapi bervariasi secara halus dalam hal ukuran, bentuk, dan variasi kecil lainnya yang tidak mengindikasikan TB. Gambar TB: Gambar-gambar ini secara khusus dipilih untuk mencakup spektrum yang luas dari manifestasi TB, termasuk stadium awal dan stadium lanjut dari penyakit ini. Keragaman Keragaman dalam subset ini sangat penting untuk melatih model untuk mengenali berbagai bentuk dan tingkat keparahan manifestasi TB. Gambar 5 menunjukkan citra kondisi normal dan TB.



Gambar Normal



Gambar TB

Gambar 4. Contoh gambar normal dan Tuberkulosis

3.2 Eksperimen Klasifikasi

Hasil kuantitatif dari metode yang diusulkan dan yang sudah ada pada dataset standar disajikan pada Tabel 1, yang menunjukkan kinerja yang mengesankan dalam klasifikasi gambar normal dan TB dibandingkan dengan kinerja model yang sudah ada. Terlihat dari Tabel 1 bahwa model yang diusulkan, yang menggunakan VGG-16 dengan CNN sebagai pengekstrak, mencapai akurasi tertinggi untuk klasifikasi gambar normal dan TB. Kerangka kerja hibrida dengan CNN dan pengklasifikasi [25] mungkin tidak sepenuhnya mengoptimalkan kinerja karena keterbatasan potensial dalam menangkap fitur kompleks yang diperlukan untuk identifikasi TB yang akurat. Demikian pula, meskipun pembelajaran transfer dengan pendekatan MobileNet dan tuning hyperparameter efektif, mereka mungkin belum sepenuhnya mengeksplorasi representasi fitur yang kaya yang diperlukan untuk kinerja yang optimal [31-32]. Selain itu, metode yang menggabungkan HOG dan LBP dengan beberapa pengklasifikasi mungkin tidak dapat menangkap fitur yang beragam dan kompleks seperti pendekatan berbasis CNN seperti VGG-16 [33]. Kinerja superior model yang diusulkan kemungkinan besar berasal dari keefektifan VGG-16 sebagai pengekstrak fitur, ditambah dengan ketangguhan pendekatan berbasis CNN untuk tugas klasifikasi gambar.

Tabel 1. Hasil Rangkuman Kinerja Model

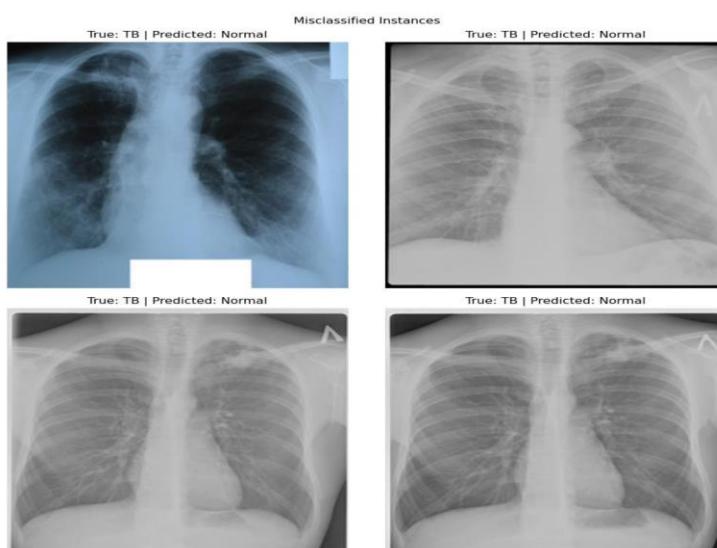
Metode	Kelas Normal		Kelas TB	
	Akurasi	Presisi	Akurasi	Presisi
Hybrid framework dengan CNN dan Classifiers [21]	96,5%	96%	97%	97%



MobileNet transfer learning model [22]	97%	95,8%	97,5%	97%
Transfer learning dan hyperparameter tuning [23]	97,8%	96%	97%	96,2%
HOG dan LBP fused dengan several classifiers [34]	97%	96%	97,3%	97,6%
Model diusulkan (VGG-16 dengan CNN sebagai Ekstraktor)	98,2%	98,4%	98,4%	98%

Gambar 5 mengilustrasikan sebuah contoh misklasifikasi citra normal dan TB oleh model yang diusulkan. Alasan misklasifikasi adalah karena adanya anomali halus yang ada pada gambar sinar-X normal, yang meniru karakteristik yang biasanya terkait dengan kelainan terkait TB. Anomali ini, meskipun tidak berbahaya, menimbulkan tantangan bagi model untuk secara akurat membedakan antara kasus TB dan kasus normal. Selain itu, misklasifikasi menyoroti variabilitas dan kompleksitas yang melekat pada gambar rontgen dada, di mana fitur-fitur yang berbeda kadang-kadang dapat mengaburkan garis antara kondisi patologis dan non-patologis. Namun, terlepas dari contoh misklasifikasi ini, sangat penting untuk mengakui ketahanan dan efektivitas keseluruhan model yang kami usulkan, yang dibuktikan dengan akurasi dan metrik kinerja yang tinggi. Hal ini menunjukkan bahwa masih ada ruang untuk perbaikan dari pekerjaan yang diusulkan. Salah satu solusi yang mungkin untuk tantangan-tantangan ini adalah mengeksplorasi model end-to-end dengan menyatukan model yang telah disempurnakan dan model bahasa. Ini akan menjadi pekerjaan kami di masa depan.

Selain itu, seperti yang dibahas dalam metode [35, 36], terkadang, jika model bekerja seperti kotak hitam, tidak mudah untuk menganalisis hasil dari model pembelajaran mesin dan dapat menyebabkan kebingungan. Salah satu alasan yang mungkin adalah pelatihan yang tidak adil dan bias, pelabelan sampel dan proses pembelajaran mesin. Penelitian ini menggunakan dataset dan label standar untuk evaluasi. Selain itu, kami mengikuti instruksi yang sama seperti yang disebutkan dalam penelitian asli untuk menghitung tingkat klasifikasi. Oleh karena itu, penting untuk memverifikasi dan memeriksa ulang seluruh proses pelabelan dan pelatihan untuk memastikan hasil yang adil dan tidak bias. Oleh karena itu, hal ini penting terutama untuk aplikasi medis, seperti identifikasi dan klasifikasi penyakit.



Gambar 5. Klasifikasi yang tidak berhasil dari metode yang diusulkan



3.3 Ringkasan Temuan Utama

Penelitian ini bertujuan untuk mengembangkan model klasifikasi berbasis pembelajaran mendalam yang dapat secara akurat membedakan antara gambar rontgen dada normal dan gambar yang terindikasi Tuberkulosis (TB). Hasil eksperimen menunjukkan bahwa model yang diusulkan, yang menggabungkan VGG-16 sebagai ekstraktor fitur dan Convolutional Neural Network (CNN) untuk klasifikasi, mencapai kinerja terbaik dibandingkan dengan metode yang sudah ada. Model ini mencapai akurasi 98,2% untuk kelas normal dan 98,4% untuk kelas TB, dengan presisi yang konsisten di atas 98% (Tabel 1). Kinerja superior ini menunjukkan efektivitas pendekatan berbasis CNN dalam menangkap fitur kompleks yang diperlukan untuk identifikasi TB.

3.4 Perbandingan dengan Penelitian Sebelumnya

Hasil penelitian ini dibandingkan dengan beberapa metode yang sudah ada, termasuk kerangka kerja hibrida dengan CNN dan pengklasifikasi [21], model pembelajaran transfer berbasis MobileNet [22], serta metode yang menggabungkan HOG (Histogram of Oriented Gradients) dan LBP (Local Binary Patterns) dengan beberapa pengklasifikasi [34]. Meskipun metode-metode tersebut menunjukkan kinerja yang baik (akurasi dan presisi di atas 96%), model yang diusulkan mengungguli mereka dalam hal akurasi dan presisi. Keunggulan ini kemungkinan besar disebabkan oleh kemampuan VGG-16 dalam mengekstrak fitur yang kaya dan mendalam, serta ketangguhan arsitektur CNN dalam memproses data gambar medis.

Temuan ini sejalan dengan penelitian sebelumnya yang menunjukkan bahwa pendekatan berbasis CNN, terutama yang menggunakan arsitektur pre-trained seperti VGG-16, efektif dalam tugas klasifikasi gambar medis [31-33]. Namun, penelitian ini juga mengidentifikasi beberapa tantangan, seperti misklasifikasi yang terjadi pada gambar normal dengan anomali halus yang menyerupai gejala TB (Gambar 5). Misklasifikasi ini menyoroti kompleksitas gambar rontgen dada, di mana fitur-fitur tertentu dapat mengaburkan batas antara kondisi patologis dan non-patologis.

Temuan ini memiliki implikasi penting untuk pengembangan sistem diagnostik berbasis AI di bidang medis. Akurasi dan presisi yang tinggi dari model yang diusulkan menunjukkan potensinya untuk digunakan sebagai alat bantu diagnosis TB, terutama di daerah dengan sumber daya terbatas. Namun, tantangan seperti misklasifikasi dan variabilitas gambar rontgen dada menggarisbawahi perlunya peningkatan lebih lanjut, termasuk penggunaan dataset yang lebih besar dan lebih beragam, serta integrasi teknik interpretabilitas model seperti Grad-CAM untuk menganalisis area gambar yang memengaruhi keputusan model.

Meskipun model yang diusulkan menunjukkan kinerja yang mengesankan, penelitian ini memiliki beberapa keterbatasan. Pertama, dataset yang digunakan relatif kecil (4.200 gambar), yang dapat membatasi generalisasi model. Kedua, meskipun model ini efektif dalam mengklasifikasikan gambar TB, interpretasi hasilnya masih terbatas karena sifat "kotak hitam" dari model pembelajaran mendalam. Terakhir, penelitian ini belum menguji model pada dataset eksternal atau dalam pengaturan klinis nyata, yang diperlukan untuk memvalidasi keandalan dan kegunaannya dalam praktik medis sehari-hari.

4. KESIMPULAN

Pengamatan terkini menunjukkan bahwa deteksi Tuberkulosis (TB) dari gambar rontgen dada merupakan tantangan kompleks yang memerlukan pendekatan canggih untuk mencapai akurasi tinggi. Dalam penelitian ini, kami mengusulkan metode baru yang menggabungkan VGG-16 sebagai ekstraktor fitur dan Convolutional Neural Network (CNN) untuk klasifikasi gambar normal dan gambar yang terindikasi TB. Hasil eksperimen



menunjukkan bahwa metode yang diusulkan mencapai akurasi 98,2% untuk kelas normal dan 98,4% untuk kelas TB, mengungguli metode-metode yang sudah ada seperti kerangka kerja hibrida CNN, MobileNet, serta metode berbasis HOG dan LBP. Temuan kami memberikan bukti konklusif bahwa pendekatan berbasis CNN, terutama yang menggunakan arsitektur pre-trained seperti VGG-16, efektif dalam menangkap fitur kompleks yang diperlukan untuk identifikasi TB. Namun, penelitian ini juga mengidentifikasi keterbatasan, seperti misklasifikasi pada gambar normal dengan anomali halus yang menyerupai gejala TB. Hal ini menyoroti perlunya peningkatan lebih lanjut dalam hal interpretabilitas model dan generalisasi pada dataset yang lebih beragam.

5. REFERENSI

- [1] Mandal, A. K. and Sarma, P. K. D. Usage of particle swarm optimization in digital images selection for monkeypox virus prediction and diagnosis. *Malaysian Journal of Computer Science*, 37, 2 (2024), 124- 138. <https://doi.org/10.22452/mjcs.vol37no2.2>.
- [2] Varsha and Maran, P. S. Multi-layered architecture convolution neural networks for diagnosing and predicting heart diseases on multi-modal. *Malaysian Journal of Computer Science*, sp2023, 1 (2023), 29- 43. <https://doi.org/10.22452/mjcs.sp2023no1.3>.
- [3] Sangermano, V., et al. Human factors implication in innovative strategies for containership fires prevention and management. *Safety Management and Human Factors* (2024). <https://doi.org/10.54941/ahfe1005313>.
- [4] Hansun, S., et al. Machine and deep learning for tuberculosis detection on chest X-rays: Systematic literature review. *Journal of Medical Internet Research*, 25 (2023), e43154. <https://doi.org/10.2196/43154>.
- [5] Rahman, T., et al. TB-CXRNet: Tuberculosis and drug-resistant tuberculosis detection technique using chest X-ray images. *Cognitive Computation*, 16, 3 (2024), 1393- 1412. <https://doi.org/10.1007/s12559-024- 10259-3>.
- [6] dos Santos, P. R. S., et al. KochDet: BiFPN-based deep architecture for tuberculosis diagnosis. *Biomedical Signal Processing and Control*, 91 (2024), 106056. <https://doi.org/10.1016/j.bspc.2024.106056>.
- [7] Sharma, S. and Guleria, K. A deep learning based model for the detection of pneumonia from chest X-ray images using VGG-16 and neural networks. *Procedia Computer Science*, 218 (2023), 357-366. <https://doi.org/10.1016/j.procs.2023.01.018>.
- [8] Hansun, S., et al. Machine and deep learning for tuberculosis detection on chest X-rays: Systematic literature review. *Journal of Medical Internet Research*, 25 (2023), e43154. <https://doi.org/10.2196/43154>.
- [9] Yao, Q.-Y., Fu, M.-L., Zhao, Q., Zheng, X.-M., Tang, K. and Cao, L.-M. Image-based visualization of stents in mechanical thrombectomy for acute ischemic stroke: Preliminary findings from a series of cases. *World Journal of Clinical Cases*, 11, 21 (2023), 5047-5055. <https://doi.org/10.12998/wjcc.v11.i21.5047>.
- [10] Ayaz, M., Shaukat, F. and Raja, G. Ensemble learning based automatic detection of tuberculosis in chest X-ray images using hybrid feature descriptors. *Physical and Engineering Sciences in Medicine*, 44, 1 (2021), 183-194. <https://doi.org/10.1007/s13246-020-00966-0>.
- [11] Ibrahim, A. U., Guler, E., Guvenir, M., Suer, K., Serte, S. and Ozsoz, M. Automated detection of Mycobacterium tuberculosis using transfer learning. *The Journal of Infection in Developing Countries*, 15, 5 (2021), 678-686. <https://doi.org/10.3855/jidc.13532>.



- [12] Gelaw, Y., Getaneh, Z. and Melku, M. Anemia as a risk factor for tuberculosis: A systematic review and meta-analysis. *Environmental Health and Preventive Medicine*, 26, 1 (2021). <https://doi.org/10.1186/s12199-020-00931-z>.
- [13] Gröschel, M. I., et al. GenTB: A user-friendly genome-based predictor for tuberculosis resistance powered by machine learning. *Genome Medicine*, 13, 1 (2021). <https://doi.org/10.1186/s13073-021-00953-4>.
- [14] Ullah, U., Tahir, Z., Qazi, O., Mirza, S. and Cheema, M. I. Tuberculosis diagnosis from sputum using Raman spectroscopy. *Biomedical Vibrational Spectroscopy 2022: Advances in Research and Industry* (2022). <https://doi.org/10.1117/12.2608594>.
- [15] Ramachandran, P. S., et al. Integrating central nervous system metagenomics and host response for diagnosis of tuberculosis meningitis and its mimics. *Nature Communications*, 13, 1 (2022). <https://doi.org/10.1038/s41467-022-29353-x>.
- [16] Kuang, X., Wang, F., Hernandez, K. M., Zhang, Z. and Grossman, R. L. Accurate and rapid prediction of tuberculosis drug resistance from genome sequence data using traditional machine learning algorithms and CNN. *Scientific Reports*, 12, 1 (2022). <https://doi.org/10.1038/s41598-022-06449-4>.
- [17] Chavan, M., Varadarajan, V., Gite, S. and Kotecha, K. Deep neural network for lung image segmentation on chest X-ray. *Technologies*, 10, 5 (2022), 105. <https://doi.org/10.3390/technologies10050105>.
- [18] Park, M., et al. Distinguishing nontuberculous mycobacterial lung disease and *Mycobacterium tuberculosis* lung disease on X-ray images using deep transfer learning. *BMC Infectious Diseases*, 23, 1 (2023). <https://doi.org/10.1186/s12879-023-07996-5>.
- [19] Boyina, K., Reddy, G. M., Akshita, G., Singh, R. P., Kumar, P. and Duraisamy, P. Detection and analysis of tuberculosis disease from chest X-ray (CXR) images using machine learning and deep learning techniques. 2024 3rd International Conference for Innovation in Technology (INOCON) (2024). <https://doi.org/10.1109/inocon60754.2024.10511723>.
- [20] Shome, N., Kashyap, R. and Laskar, R. H. Detection of tuberculosis using customized MobileNet and transfer learning from chest X-ray image. *Image and Vision Computing*, 147 (2024), 105063. <https://doi.org/10.1016/j.imavis.2024.105063>.
- [21] Wajgi, R., et al. Optimized tuberculosis classification system for chest X-ray images: Fusing hyperparameter tuning with transfer learning approaches. *Engineering Reports* (2024).
- [22] Rahman, T., et al. TB-CXRNet: Tuberculosis and drug-resistant tuberculosis detection technique using chest X-ray images. *Cognitive Computation*, 16, 3 (2024), 1393-1412. <https://doi.org/10.1007/s12559-024-10259-3>.
- [23] Smith, J. P., Milligan, K., McCarthy, K. D., McHembere, W., Okeyo, E., Musau, S. K., et al. Machine learning to predict bacteriologic confirmation of *Mycobacterium tuberculosis* in infants and very young children. *PLOS Digital Health*, 2, 5 (2023), e0000249. <https://doi.org/10.1371/journal.pdig.0000249>.
- [24] D. R., Sreevalli, B. M., Kulkarni, S., Gudla, S. and B. J., S. DeepXray: A deep learning based system for tuberculosis detection and severity prediction in chest X-rays. 2024 IEEE 9th International Conference for Convergence in Technology (I2CT) (2024). <https://doi.org/10.1109/i2ct61223.2024.10543961>.
- [25] Genitha, C. H., Kalaivani, I., Ajibah, A. S. H., Jalagandeswaran, S. and Balamurugan, K. Automated framework for the tuberculosis detection and classification in X-ray images using deep learning algorithm. 2023 International Conference on Self Sustainable Artificial Intelligence Systems (ICSSAS) (2023). <https://doi.org/10.1109/icssas57918.2023.10331715>
- [26] Liu, Y., Wu, Y.-H., Zhang, S.-C., Liu, L., Wu, M. and Cheng, M.-M. Revisiting computer-aided tuberculosis diagnosis. *IEEE Transactions on Pattern Analysis and*



Machine Intelligence, 46, 4 (2024), 2316-2332.
<https://doi.org/10.1109/tpami.2023.3330825>.

- [27] Hossain, S., Islam, A., Lima, S., Ridoy, Md. S., Rahman, Md. M. and Sharmin, S. An effective identification of tuberculosis in chest X-rays using convolutional neural network model. 2024 6th International Conference on Electrical Engineering and Information & Communication Technology (ICEEICT) (2024). <https://doi.org/10.1109/iceeict62016.2024.10534374>.
- [28] Perez-Siguas, R., Matta-Solis, E., Remuzgo-Artezano, A., Matta-Solis, H., Matta-Perez, H. and Perez-Siguas, L. Chest X-ray imaging system for early detection of tuberculosis. 2023 Third International Conference on Advances in Electrical, Computing, Communication and Sustainable Technologies (ICAECT) (2023). <https://doi.org/10.1109/icaect57570.2023.10117936>.
- [29] Ogunlade, B., et al. Rapid, antibiotic incubation-free determination of tuberculosis drug resistance using machine learning and Raman spectroscopy. Proceedings of the National Academy of Sciences, 121, 25 (2024). <https://doi.org/10.1073/pnas.2315670121>.
- [30] Hrizi, O., et al. Tuberculosis disease diagnosis based on an optimized machine learning model. Journal of Healthcare Engineering, 2022 (2022), 1-13. <https://doi.org/10.1155/2022/8950243>.
- [31] Xie, X., et al. Evaluating cancer-related biomarkers based on pathological images: A systematic review. Frontiers in Oncology, 11 (2021). <https://doi.org/10.3389/fonc.2021.763527>.
- [32] He, B., et al. A new method for CTC images recognition based on machine learning. Frontiers in Bioengineering and Biotechnology, 8 (2020). <https://doi.org/10.3389/fbioe.2020.00897>.
- [33] Singh, M., et al. Evolution of machine learning in tuberculosis diagnosis: A review of deep learning-based medical applications. Electronics, 11, 17 (2022), 2634. <https://doi.org/10.3390/electronics11172634>.
- [34] Amin, S. U., Taj, S., Hussain, A. and Seo, S. An automated chest X-ray analysis for COVID-19, tuberculosis, and pneumonia employing ensemble learning approach. Biomedical Signal Processing and Control, 87 (2024), 105408. <https://doi.org/10.1016/j.bspc.2023.105408>.
- [35] Vimbi, V., Shaffi, N. and Mahmud, M. Interpreting artificial intelligence models: A systematic review on the application of LIME and SHAP in Alzheimer's disease detection. Brain Informatics, 11, 1 (2024). <https://doi.org/10.1186/s40708-024-0022-1>.
- [36] Viswan, V., Shaffi, N., Mahmud, M., Subramanian, K. and Hajamohideen, F. Explainable artificial intelligence in Alzheimer's disease classification: A systematic review. Cognitive Computation, 16, 1 (2023), 1-44. <https://doi.org/10.1007/s12559-023-10192-x>.