

Chest X-Ray Based Pulmonary Tuberculosis Classification Using Transfer Learning with DenseNet121 and Convolutional Block Attention Module (CBAM)

Ikfina Kamaliya Rizqi¹, Catur Supriyanto^{2*}

Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Dian Nuswantoro, Semarang, Indonesia

111202214170@mhs.dinus.ac.id¹, catur.supriyanto@dsn.dinus.ac.id²

Article Info

Article history:

Received 2026-02-19

Revised 2026-03-10

Accepted 2026-04-10

Keyword:

Pulmonary Tuberculosis,

DenseNet121,

CBAM,

Image Classification,

Deep Learning.

ABSTRACT

Pulmonary tuberculosis is one of the infectious diseases with a high morbidity rate, requiring an accurate and efficient diagnostic support system based on chest X-ray images. This study aims to develop and evaluate a pulmonary tuberculosis classification model using the DenseNet121 architecture and DenseNet121 combined with the Convolutional Block Attention Module (CBAM) with a transfer learning approach. The research design is experimental using a dataset of 3.008 chest X-ray images consisting of 2.494 tuberculosis and 514 normal images, divided into two data partitioning scenarios, namely 60:20:20 and 70:15:15 for training, validation, and testing data. The training process was carried out for 20 epochs using the Adam optimizer. Model performance evaluation was carried out using accuracy, precision, recall, F1-score, and confusion matrix metrics. The results showed that the DenseNet121 model without the attention mechanism achieved an accuracy of 99% in both data division scenarios. Meanwhile, the DenseNet121 + CBAM model produced improved performance with accuracy, precision, recall, and F1-score values of 1.00 on the test data, with no False Positive or False Negative errors found. These findings indicate that the integration of CBAM can improve the model's ability to extract relevant features and increase the sensitivity of pulmonary tuberculosis detection. Overall, this study shows that the application of the attention mechanism in the DenseNet121 architecture has the potential to improve the performance of chest X-ray-based pulmonary tuberculosis classification systems.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

I. PENDAHULUAN

Tuberkulosis paru merupakan salah satu penyakit infeksi menular yang hingga saat ini masih menjadi permasalahan kesehatan global dengan tingkat morbiditas dan mortalitas yang tinggi, khususnya di negara berkembang seperti Indonesia. Tingginya jumlah kasus tuberkulosis paru menuntut adanya proses diagnosis yang cepat, akurat, dan konsisten agar penanganan pasien dapat dilakukan secara optimal. Dalam praktik klinis, tuberkulosis paru umumnya didiagnosis melalui pemeriksaan rontgen dada yang kemudian diinterpretasikan oleh tenaga medis profesional. Namun, proses evaluasi citra rontgen secara manual bersifat subjektif dan sangat bergantung pada pengalaman radiolog, sehingga berpotensi menimbulkan kesalahan diagnosis, terutama ketika tampilan visual tuberkulosis memiliki kemiripan dengan penyakit paru-paru lainnya [1], [2].

Kemajuan teknologi kecerdasan buatan, terutama dalam ranah deep learning, telah mempercepat pengembangan sistem otomatis yang berperan dalam mendukung analisis citra medis. Melalui pendekatan ini, sistem komputer mampu mempelajari pola-pola kompleks pada citra secara langsung dari data tanpa bergantung pada proses ekstraksi fitur secara manual. Convolutional Neural Network (CNN) menjadi salah satu arsitektur deep learning yang paling populer dalam analisis citra medis maupun non-medis. Keunggulan utamanya terletak pada kemampuan mengekstraksi fitur secara otomatis dari data visual tanpa perlu rekayasa fitur manual, sehingga menghasilkan akurasi yang lebih baik dibandingkan metode pemrosesan citra tradisional [3]. Penelitian lain juga menunjukkan bahwa penerapan arsitektur deep CNN seperti ResNet dan model multi-arsitektur pada citra rontgen dada mampu meningkatkan performa klasifikasi penyakit secara signifikan dalam berbagai skenario

pengujian[4]. Berbagai penelitian telah menerapkan CNN dan teknik transfer learning untuk mengklasifikasikan penyakit paru-paru berdasarkan citra rontgen dada, termasuk pneumonia, COVID-19, dan tuberkulosis, dengan hasil yang menunjukkan kinerja yang menjanjikan dalam pengembangan sistem bantu diagnosis berbasis komputer [5], [6]. Studi terbaru juga melaporkan bahwa penerapan CNN untuk klasifikasi tuberkulosis paru berbasis citra rontgen dada mampu menghasilkan akurasi yang tinggi serta performa klasifikasi yang stabil pada berbagai konfigurasi model [7]. Studi mengenai klasifikasi pneumonia dan COVID-19 berbasis transfer learning juga menunjukkan bahwa penggunaan model pra-latih mampu meningkatkan akurasi serta mempercepat proses pelatihan dibandingkan pelatihan dari awal [8]. Penelitian internasional terkini juga melaporkan bahwa model deep learning berbasis transfer learning mampu mencapai nilai AUC di atas 0,95 dalam klasifikasi manifestasi tuberkulosis aktif berdasarkan zona paru pada citra rontgen dada, serta tetap menunjukkan performa yang stabil pada dataset eksternal lintas wilayah geografis, sehingga menegaskan potensi generalisasi model AI dalam skenario klinis nyata [9]. Selain itu, tinjauan sistematis tentang penerapan machine learning dan deep learning dalam deteksi tuberkulosis pada rontgen dada menunjukkan bahwa pendekatan deep learning secara konsisten unggul dibandingkan metode konvensional dan memiliki potensi signifikan untuk implementasi klinis [10].

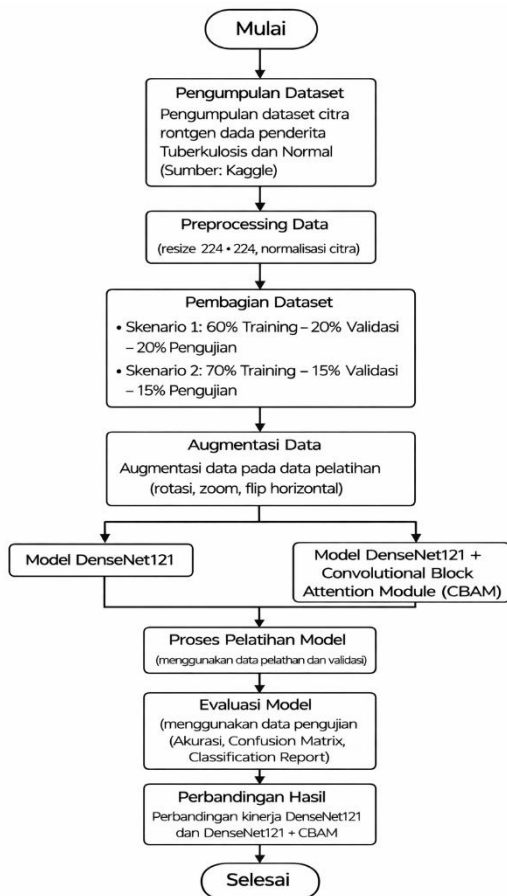
Transfer learning merupakan strategi yang sering diterapkan dalam pengembangan model deep learning untuk mengatasi keterbatasan data pelatihan. Dengan memanfaatkan pengetahuan dari model yang telah dilatih sebelumnya, pendekatan ini mampu meningkatkan akurasi dan stabilitas model meskipun data tersedia dalam jumlah terbatas. Salah satu arsitektur CNN yang sering digunakan dalam pendekatan transfer learning khususnya pada klasifikasi citra medis adalah DenseNet121. Arsitektur ini dikenal memiliki efisiensi parameter yang tinggi serta kemampuan untuk mempertahankan aliran informasi fitur melalui koneksi padat antar lapisan, sehingga mampu meningkatkan proses pembelajaran dan kualitas ekstraksi fitur [11]. Penggunaan DenseNet121 dan ResNet50 dalam berbagai penelitian klasifikasi citra medis juga menunjukkan performa yang kompetitif pada dataset tumor otak dan citra medis lainnya [12].

Meskipun demikian, sebagian besar penelitian sebelumnya masih menggunakan arsitektur CNN tanpa mekanisme perhatian [13], sehingga proses pembelajaran model belum sepenuhnya terfokus pada area paru-paru yang paling penting dalam citra rontgen dada. Kondisi ini dapat menyebabkan model mempelajari fitur-fitur yang kurang sesuai dengan kondisi sebenarnya dari bagian paru-paru yang mengalami kelainan atau penyakit. Selain itu, beberapa penelitian lebih memfokuskan pada klasifikasi penyakit paru-paru selain tuberkulosis, seperti pneumonia dan COVID-19, sehingga kajian yang secara khusus membahas klasifikasi tuberkulosis paru masih relatif terbatas. Beberapa penelitian tentang

klasifikasi tuberkulosis berbasis deep learning masih mengandalkan arsitektur CNN konvensional tanpa mengintegrasikan mekanisme perhatian [14]. Akibatnya, potensi peningkatan fokus model melalui Channel Attention dan Spatial Attention belum dimanfaatkan secara optimal. Di sisi lain, sejumlah penelitian masih menggunakan pendekatan berbasis fitur manual seperti *Gray Level Co-occurrence Matrix* (GLCM) dan filter Gabor, yang meskipun mampu menangkap karakteristik tekstur citra, namun menghasilkan kinerja yang relatif lebih rendah dibandingkan pendekatan deep learning modern [15], [16]. Perbandingan antara metode pembelajaran mesin tradisional dan deep learning menunjukkan bahwa model berbasis CNN umumnya memiliki sensitivitas dan spesifisitas yang lebih tinggi dalam mendeteksi kelainan paru pada citra rontgen dada [15], [16].

Penelitian terkini menunjukkan bahwa pengembangan arsitektur deep learning yang lebih modern serta penerapan komponen tambahan dalam model mampu meningkatkan kinerja klasifikasi citra medis. Beberapa studi melaporkan bahwa penggunaan mekanisme perhatian dapat membantu model untuk lebih fokus pada bagian citra yang memiliki kontribusi paling besar dalam proses pengambilan keputusan, serta memperbaiki akurasi dan kemampuan generalisasi model. Penerapan Convolutional Block Attention Module (CBAM) pada klasifikasi citra rontgen dada dan penyakit paru lainnya juga terbukti mampu meningkatkan representasi fitur melalui integrasi Channel Attention dan Spatial Attention [13]. Integrasi mekanisme perhatian pada arsitektur CNN modern juga dilaporkan mampu meningkatkan akurasi dan stabilitas model dibandingkan CNN konvensional [17]. Namun, penerapan Channel Attention secara khusus untuk klasifikasi tuberkulosis paru berbasis citra rontgen dada masih relatif terbatas, dan sebagian penelitian masih menggunakan CNN konvensional tanpa mekanisme perhatian atau berpotensi mengalami *overfitting* akibat keterbatasan data pelatihan [2], [5]. Oleh karena itu, diperlukan penelitian yang secara spesifik mengevaluasi integrasi arsitektur DenseNet121 dengan mekanisme Convolutional Block Attention Module (CBAM) dalam klasifikasi tuberkulosis paru berbasis citra rontgen dada.

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk merancang sistem klasifikasi tuberkulosis paru berbasis citra rontgen dada dengan memanfaatkan arsitektur DenseNet121 melalui pendekatan transfer learning yang dikombinasikan dengan Convolutional Block Attention Module (CBAM), serta membandingkan kinerjanya dengan model DenseNet121 tanpa mekanisme perhatian. Pendekatan ini dirancang untuk meningkatkan fokus model terhadap area paru-paru yang memiliki kontribusi penting dalam diagnosis tuberkulosis melalui integrasi mekanisme perhatian. Penerapan CBAM diharapkan dapat membantu model dalam mempelajari informasi penting melalui mekanisme Channel Attention dan Spatial Attention, sehingga fokus model terhadap area paru-paru yang relevan dapat ditingkatkan. Kontribusi utama penelitian ini adalah integrasi mekanisme



Gambar 1 Alur Metodologi Penelitian

perhatian CBAM pada arsitektur DenseNet121 untuk meningkatkan akurasi dan keandalan kinerja klasifikasi tuberkulosis paru dibandingkan dengan pendekatan CNN konvensional yang telah digunakan pada penelitian-penelitian sebelumnya.

Berbeda dengan penelitian sebelumnya yang sebagian besar hanya menggunakan arsitektur CNN konvensional tanpa mekanisme perhatian, atau berfokus pada klasifikasi penyakit paru selain tuberkulosis seperti pneumonia dan COVID-19, penelitian ini secara spesifik mengintegrasikan CBAM pada arsitektur DenseNet121 dengan pendekatan transfer learning untuk klasifikasi tuberkulosis paru berbasis citra rontgen dada. Kebaruan penelitian ini terletak pada kombinasi DenseNet121 sebagai backbone dengan CBAM sebagai mekanisme perhatian yang bekerja secara berurutan melalui Channel Attention dan Spatial Attention, serta evaluasi konsistensi model pada dua skenario pembagian data yang berbeda. Pendekatan ini diharapkan dapat memberikan kontribusi nyata dalam pengembangan sistem bantu diagnosis tuberkulosis paru yang lebih akurat dan andal dibandingkan metode-metode yang telah ada sebelumnya.

II. METODE

Penelitian ini dilakukan untuk mengklasifikasikan tuberkulosis paru menggunakan deep learning berdasarkan citra rontgen dada. Tahapan penelitian meliputi pengumpulan dataset, preprocessing dan augmentasi data, pembagian dataset, perancangan arsitektur model, proses pelatihan, dan evaluasi kinerja model. Model yang digunakan dalam penelitian ini adalah DenseNet121 sebagai model dasar dan DenseNet121 yang dikombinasikan dengan Convolutional Block Attention Module (CBAM) untuk meningkatkan kemampuan model dalam mengekstrak fitur penting pada citra rontgen dada. Proses metodologi penelitian disusun secara sistematis untuk memastikan proses klasifikasi berjalan efektif dan mencapai kinerja optimal. Seperti diilustrasikan pada Gambar 1, alur penelitian terdiri dari enam tahapan, utama: (1) pengumpulan dataset citra rontgen dada dari sumber publik, (2) preprocessing citra meliputi resizing ke ukuran 224×224 piksel dan normalisasi nilai piksel, (3) augmentasi data pada kelas minoritas untuk mengatasi ketidakseimbangan kelas, (4) pembagian dataset menjadi data latih, validasi, dan uji dalam dua skenario (60:20:20 dan 70:15:15), (5) perancangan dan pelatihan dua arsitektur model (DenseNet121 baseline dan DenseNet121+CBAM) menggunakan pendekatan transfer learning, serta (6) evaluasi kinerja model dilakukan pada data uji yang terpisah dari data latih dengan menggunakan metrik accuracy, precision, recall, F1-score, dan confusion matrix untuk menilai kemampuan prediksi model secara komprehensif.

Pada tahap pembagian dataset, penelitian ini menerapkan dua skenario pembagian data, yaitu skenario pertama dengan rasio 60% data latih, 20% data validasi, dan 20% data uji, serta skenario kedua dengan rasio 70% data latih, 15% data validasi, dan 15% data uji. Kedua skenario tersebut digunakan untuk mengevaluasi konsistensi kinerja model terhadap perbedaan proporsi data pelatihan dan pengujian. Seluruh tahapan berikutnya, termasuk preprocessing, augmentasi, pelatihan, dan evaluasi model, diterapkan secara konsisten pada kedua skenario pembagian dataset.

A. Deskripsi Dataset

Penelitian ini menggunakan dataset publik berupa citra rontgen dada yang diunduh dari platform Kaggle dengan judul "Tuberculosis Chest X-rays Images." Dataset ini disusun oleh Yasir Hussein Shakir dan berlisensi Creative Commons Attribution-ShareAlike 4.0 (CC BY-SA 4.0), yang berarti dataset ini dapat digunakan untuk tujuan penelitian ilmiah.

Kumpulan dataset ini terdiri dari 3.008 citra rontgen dada, dibagi menjadi dua kelas, yaitu 2.494 citra paru-paru dengan tuberkulosis (TBC) dan 514 citra paru-paru normal. Citra-citra dalam kumpulan dataset ini mewakili kondisi klinis nyata, di mana perbedaan visual antara paru-paru normal dan paru-paru dengan tuberkulosis seringkali halus dan kompleks.

Gambar 2 menampilkan contoh citra rontgen dada dari dataset yang digunakan dalam penelitian ini untuk kelas paru-paru normal dan tuberkulosis.



Gambar 2 Contoh citra Normal (kiri) dan citra TBC (kanan)

Dataset ini dipilih karena merupakan dataset publik yang telah terverifikasi, memiliki kualitas citra yang memadai, dan penggunaannya yang luas dalam penelitian sebelumnya mengenai klasifikasi penyakit paru-paru menggunakan deep learning. Penggunaan dataset publik juga memungkinkan replikasi proses penelitian ini dan perbandingan hasil dengan penelitian lain yang menggunakan dataset serupa.

B. Pembagian Dataset

Dataset citra rontgen dada yang digunakan dalam penelitian ini dibagi menjadi tiga bagian, yaitu data latih, data validasi, dan data uji. Untuk menganalisis konsistensi kinerja model dengan pembagian data yang berbeda, dua skenario pembagian dataset diterapkan dalam penelitian ini, yaitu pembagian dengan rasio 60% data latih, 20% data validasi, dan 20% data uji, serta pembagian dengan rasio 70% data latih, 15% data validasi, dan 15% data uji.

Dalam skenario pembagian 60:20:20, data latih terdiri dari 1.804 citra, termasuk 1.496 citra tuberkulosis (TBC) dan 308 citra normal. Data validasi terdiri dari 600 citra, termasuk 498 citra TBC dan 102 citra normal. Data uji terdiri dari 604 citra, termasuk 500 citra TBC dan 104 citra normal.

Dalam skenario pembagian 70:15:15, data latih terdiri dari 2.104 citra, termasuk 1.745 citra TBC dan 359 citra normal. Data validasi terdiri dari 451 citra, termasuk 374 citra TBC dan 77 citra normal. Data uji terdiri dari 453 citra, termasuk 375 citra TBC dan 78 citra normal.

Secara keseluruhan, dataset yang digunakan dalam penelitian ini terdiri dari 3.008 citra, termasuk 2.494 citra TBC dan 514 citra normal. Data latih digunakan untuk proses pembelajaran model, data validasi digunakan untuk memantau kinerja model selama pelatihan dan mencegah *overfitting*, sementara data uji digunakan untuk mengevaluasi kinerja model akhir.

Distribusi kelas dalam dataset menunjukkan ketidakseimbangan antara jumlah citra TBC dan citra normal, mencerminkan kondisi sebenarnya dalam data klinis. Untuk mengurangi dampak ketidakseimbangan kelas pada proses

pembelajaran model, data latih diaugmentasi dan berbagai metrik evaluasi seperti accuracy, precision, recall, dan F1-score digunakan untuk mendapatkan gambaran yang lebih komprehensif tentang kinerja model.

C. Preprocessing Data

Sebelum proses pelatihan model dilakukan, semua citra rontgen dada menjalani tahap preprocessing untuk memastikan keseragaman dan konsistensi data. Langkah ini penting karena citra dari sumber yang sama dapat bervariasi dalam hal resolusi, skala, dan distribusi intensitas piksel.

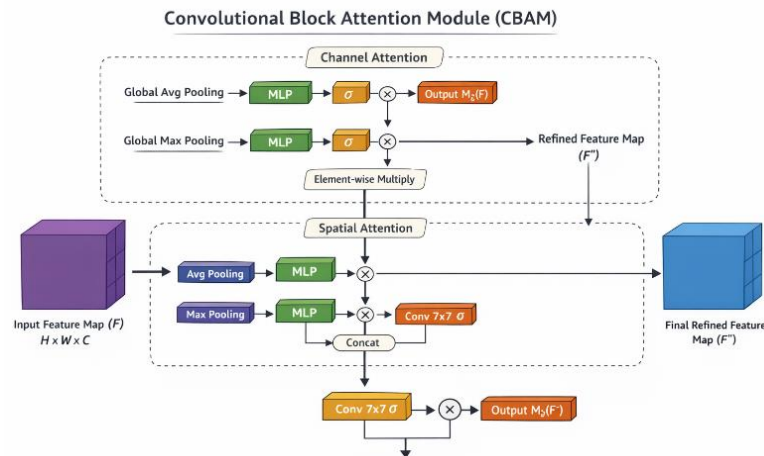
Langkah pertama adalah mengubah ukuran (*resize*) seluruh citra menjadi 224×224 piksel. Ukuran ini dipilih karena sesuai dengan spesifikasi input arsitektur DenseNet121 yang digunakan dalam penelitian ini. Proses *resize* memastikan semua citra memiliki dimensi yang seragam sehingga dapat diproses secara optimal oleh jaringan saraf konvolusional.

Langkah kedua adalah normalisasi nilai piksel dengan membagi setiap nilai piksel dengan 255, sehingga rentang nilai piksel berubah dari $[0, 255]$ menjadi $[0, 1]$. Normalisasi bertujuan untuk mengurangi perbedaan skala nilai piksel antar citra, menstabilkan distribusi nilai piksel pada setiap channel, dan mempercepat proses konvergensi selama pelatihan model.

Seluruh tahapan preprocessing ini diterapkan secara konsisten pada seluruh dataset, termasuk data latih, data validasi, dan data uji, untuk memastikan bahwa perbedaan kinerja model tidak dipengaruhi oleh perlakuan data yang berbeda.

D. Augmentasi Data

Agar model tidak mudah menghafal pola data latih dan mampu mengenali variasi gambar di dunia nyata, dilakukan augmentasi data pada dataset latih. Teknik ini menghasilkan variasi baru dari citra rontgen dada melalui modifikasi geometris dan intensitas citra. Teknik augmentasi yang diterapkan dalam penelitian ini meliputi rotasi citra (*rotation*



Gambar 3 Arsitektur CBAM

range) dengan sudut rotasi acak hingga ± 15 derajat untuk mensimulasikan variasi posisi tubuh pasien saat pengambilan foto rontgen, zoom acak (zoom range) sebesar 10% untuk mensimulasikan variasi jarak pengambilan citra, serta pemantulan horizontal (horizontal flip) untuk mensimulasikan variasi orientasi citra rontgen dada. Selain itu, normalisasi nilai piksel (rescale) dilakukan dengan membagi setiap nilai piksel dengan 255 sehingga rentang nilai piksel berubah dari $[0, 255]$ menjadi $[0, 1]$.

Augmentasi diterapkan secara konsisten pada kedua model, yaitu DenseNet121 dan DenseNet121+CBAM, dan hanya dikenakan pada data latih. Sementara itu, data validasi dan data uji hanya dinormalisasi tanpa augmentasi tambahan. Hal ini dilakukan untuk memastikan objektivitas evaluasi kinerja model dan mencerminkan kinerja model pada data yang tidak dimodifikasi, sebagaimana praktik standar dalam pengembangan model deep learning untuk klasifikasi citra medis.

E. Arsitektur Model

Arsitektur model yang digunakan dalam penelitian ini dirancang untuk mengklasifikasikan citra rontgen dada menjadi dua kelas, yaitu paru-paru normal dan paru-paru dengan tuberkulosis. Penelitian ini menggunakan dua arsitektur model utama, yaitu DenseNet121 sebagai model dasar (*baseline*) dan DenseNet121 yang dikombinasikan dengan Convolutional Block Attention Module (CBAM). Kedua model disusun menggunakan pendekatan transfer learning, dengan memanfaatkan bobot yang telah dilatih sebelumnya untuk meningkatkan kemampuan ekstraksi fitur dan mempercepat proses konvergensi selama pelatihan. Perancangan dua arsitektur ini bertujuan untuk menganalisis pengaruh penerapan mekanisme perhatian CBAM terhadap kinerja klasifikasi tuberkulosis paru.

- 1) *DenseNet121*: Model *DenseNet121* digunakan sebagai model dasar (*baseline*) dalam penelitian ini. Arsitektur DenseNet121 memiliki karakteristik utama berupa koneksi antar-layer secara padat (*dense connectivity*), di mana setiap lapisan menerima masukan dari seluruh lapisan

sebelumnya. Pendekatan ini memungkinkan aliran informasi dan gradien yang lebih optimal selama proses pelatihan, sehingga dapat mengurangi risiko terjadinya vanishing gradient serta meningkatkan efisiensi pembelajaran fitur. Pada penelitian ini, DenseNet121 diinisialisasi menggunakan bobot awal (*pre-trained weights*) dari dataset ImageNet. Penggunaan bobot awal tersebut bertujuan untuk mempercepat proses konvergensi dan meningkatkan kemampuan model dalam mengekstrak fitur visual dasar sebelum melakukan fine-tuning pada dataset rontgen dada.

Lapisan akhir (*classifier layer*) pada DenseNet121 kemudian dimodifikasi agar sesuai dengan kebutuhan penelitian, yaitu untuk mengklasifikasikan dua kelas, rontgen dada normal dan tuberkulosis (TBC). Penyesuaian dilakukan dengan mengubah jumlah neuron pada lapisan output dan menggunakan fungsi aktivasi softmax untuk menentukan probabilitas prediksi untuk setiap kelas.

- 2) *DenseNet121 dengan CBAM*: Dalam arsitektur kedua, DenseNet121 digabungkan dengan Convolutional Block Attention Module (CBAM) untuk meningkatkan kemampuan ekstraksi fitur dari citra rontgen dada. CBAM merupakan modul perhatian ringan yang bekerja secara berurutan melalui dua mekanisme komplementer, sebagaimana dijelaskan pada Gambar 3. Pertama, Channel Attention menghitung bobot kepentingan setiap channel fitur dengan menerapkan global average pooling dan global max pooling secara paralel pada feature map, lalu menggabungkan hasilnya melalui shared multi-layer perceptron (MLP) untuk menghasilkan peta perhatian

channel. Kedua, Spatial Attention memproses feature map hasil Channel Attention dengan menerapkan average pooling dan max pooling sepanjang dimensi channel, menggabungkan

keduanya, lalu melewati hasilnya melalui konvolusi 7×7 untuk menghasilkan peta perhatian spasial yang menyoroti lokasi anatomis relevan pada citra. Integrasi kedua mekanisme ini memungkinkan model secara simultan mempelajari fitur apa yang penting (channel) dan di mana lokasinya (spasial) pada citra rontgen dada, sehingga meningkatkan fokus pada area paru-paru yang mengandung pola khas tuberkulosis seperti infiltrat atau kavitas.

Pada tahap Channel Attention, model berfokus pada penentuan channel fitur yang paling relevan terhadap tugas klasifikasi tuberkulosis paru. Diberikan feature map input $F \in \mathbb{R}^{H \times W \times C}$, dilakukan global average pooling dan global max pooling untuk memperoleh representasi global setiap channel. Kedua hasil pooling tersebut kemudian dilewatkan ke multi-layer perceptron (MLP) yang sama dan digabungkan, kemudian diaktifkan menggunakan fungsi *sigmoid* untuk menghasilkan peta perhatian channel, yang dirumuskan sebagai:

$$M_c(F) = \sigma(\text{MLP}(\text{AvgPool}(F)) + \text{MLP}(\text{MaxPool}(F)))$$

Feature map hasil Channel Attention diperoleh melalui perkalian elemen antara peta perhatian channel dengan feature map awal. Selanjutnya, feature map hasil Channel Attention diproses oleh Spatial Attention untuk menentukan lokasi spasial yang paling informatif pada citra rontgen dada. Pada tahap ini, dilakukan average pooling dan max pooling sepanjang dimensi channel, kemudian kedua hasil tersebut digabungkan dan dilewatkan ke lapisan konvolusi dengan ukuran *kernel* 7×7 . Hasil konvolusi selanjutnya diaktifkan menggunakan fungsi *sigmoid* untuk menghasilkan peta perhatian spasial, yang dirumuskan sebagai:

$$M_s(F') = \sigma(\text{Conv}_{7 \times 7}([\text{AvgPool}(F'); \text{MaxPool}(F')]))$$

Peta perhatian spasial yang diperoleh selanjutnya dikalikan secara elemen dengan feature map hasil mekanisme Channel Attention untuk menghasilkan feature map akhir F'' . Melalui mekanisme ini, CBAM memungkinkan model untuk menekankan channel fitur yang penting sekaligus memfokuskan perhatian pada area spasial yang relevan, sehingga mampu meningkatkan kinerja klasifikasi tuberkulosis paru dibandingkan dengan DenseNet121 tanpa mekanisme perhatian.

F. Pelatihan Model

Proses pelatihan model dilakukan menggunakan data latih (*training set*) dan divalidasi menggunakan data validasi (*validation set*) untuk memantau kinerja model selama proses pembelajaran. Selama pelatihan, mekanisme penyimpanan model terbaik (*model checkpoint*) diterapkan berdasarkan kinerja data validasi untuk mencegah *overfitting* dan memastikan bahwa model yang digunakan pada fase evaluasi adalah model dengan kinerja terbaik. Pelatihan model dilakukan dengan jumlah *epoch* yang sama, yaitu 20 *epoch*, untuk semua skenario eksperimen. Penetapan jumlah *epoch* yang konsisten bertujuan untuk memastikan perbandingan kinerja antara model adil dan tidak dipengaruhi oleh perbedaan durasi pelatihan.

Eksperimen pelatihan dilakukan dalam dua skenario pembagian dataset, yaitu 60:20:20 dan 70:15:15, baik untuk model DenseNet121 maupun model DenseNet121 yang dikombinasikan dengan Convolutional Block Attention Module (CBAM). Penggunaan skema pelatihan yang sama untuk kedua arsitektur dan kedua skenario pembagian data bertujuan untuk memastikan konsistensi dalam proses eksperimental, sehingga perbedaan kinerja yang dicapai dapat langsung dikaitkan dengan perbedaan arsitektur model dan variasi pembagian data yang digunakan.

Penelitian ini tidak menerapkan k-fold cross-validation dalam proses evaluasi model. Keputusan ini didasarkan pada beberapa pertimbangan. Pertama, dataset yang digunakan memiliki jumlah citra yang cukup besar yaitu 3.008 citra, sehingga pemisahan data menjadi data latih, validasi, dan uji sudah cukup representatif untuk mengevaluasi kinerja model. Kedua, penelitian ini menerapkan dua skenario pembagian data yang berbeda yaitu 60:20:20 dan 70:15:15, yang berfungsi sebagai pendekatan alternatif untuk menguji konsistensi dan stabilitas kinerja model pada proporsi data yang berbeda. Ketiga, penggunaan model checkpoint berdasarkan kinerja data validasi memastikan bahwa model yang dievaluasi adalah model dengan kemampuan generalisasi terbaik. Konsistensi hasil evaluasi pada kedua skenario pembagian data mengindikasikan bahwa model memiliki stabilitas kinerja yang baik meskipun tanpa penerapan k-fold cross-validation.

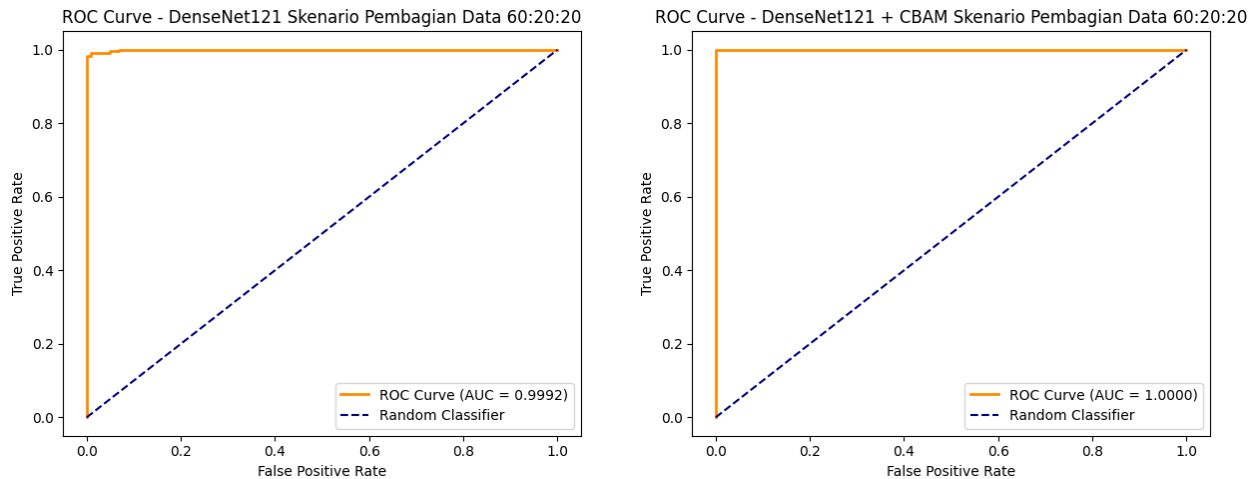
G. Konfigurasi Pelatihan Model

Konfigurasi pelatihan model disusun untuk memastikan bahwa proses pembelajaran stabil dan konsisten di seluruh arsitektur dan skenario pembagian data. Parameter pelatihan ditetapkan berdasarkan praktik umum dalam pengembangan model pembelajaran mendalam untuk klasifikasi citra medis. Rincian konfigurasi pelatihan yang digunakan dalam penelitian ini tercantum dalam Tabel I.

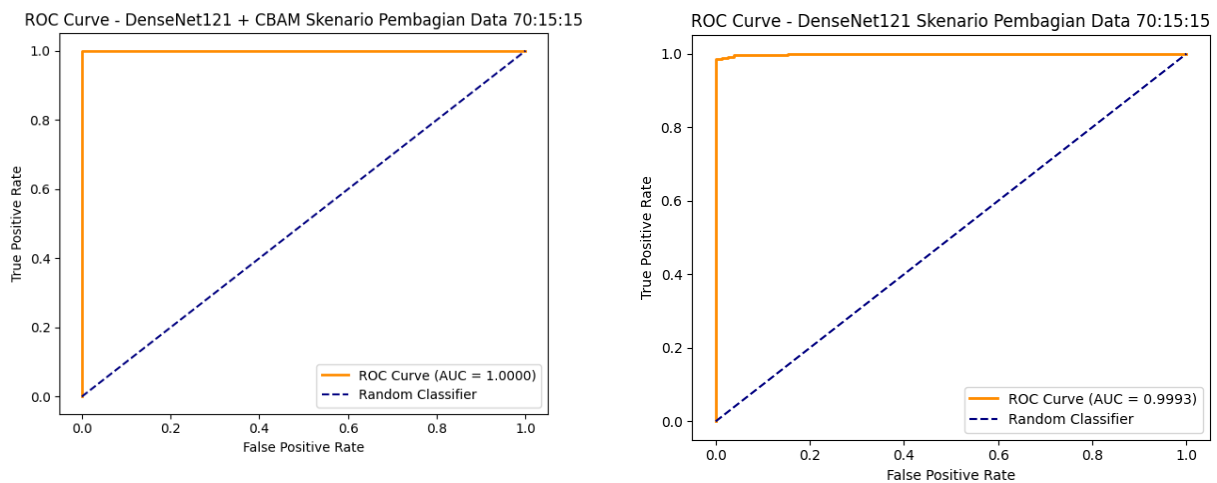
TABEL I
KONFIGURASI PELATIHAN

Parameter	Nilai
Framework	TensorFlow / Keras
Optimizer	Adam
Learning Rate	0,0001 (1e-4)
Loss Function	categorical_crossentropy
Batch Size	16
Jumlah <i>Epoch</i>	20
Metrics Evaluasi	<i>Accuracy</i>

Berdasarkan Tabel I, proses pelatihan dilakukan dengan Adam Optimizer dan learning rate 0,0001. Adam Optimizer dipilih karena dapat mempercepat konvergensi dan memastikan stabilitas pembaruan bobot selama pelatihan. Tingkat pembelajaran yang relatif rendah digunakan untuk



Gambar 4 Kurva ROC Model DenseNet121 dan DenseNet121+CBAM pada Skenario Pembagian Data 60:20:20



Gambar 5 Kurva ROC Model DenseNet121 dan DenseNet121+CBAM pada Skenario Pembagian Data 70:15:15

mengontrol tingkat perubahan bobot, sehingga proses pembelajaran menjadi lebih stabil dan fluktuasi nilai loss yang signifikan dapat dihindari.

Loss function `categorical_crossentropy` digunakan karena merupakan klasifikasi dua kelas dengan representasi label dalam bentuk one-hot encoding. Proses pelatihan dilakukan selama 20 *epoch* dengan ukuran batch 16 untuk memastikan keseimbangan antara efisiensi komputasi dan stabilitas pembelajaran. Akurasi digunakan sebagai metrik penilaian selama proses pelatihan dan validasi untuk memantau kinerja model. Selain itu, selama fase evaluasi, kinerja model dianalisis lebih lanjut menggunakan data uji berdasarkan metrik precision, recall, dan F1-score untuk mendapatkan gambaran yang lebih komprehensif tentang kinerja klasifikasi.

Secara keseluruhan, konfigurasi pelatihan ini diterapkan secara konsisten pada seluruh arsitektur dan semua skenario data untuk memastikan perbandingan kinerja model yang adil dan terkontrol.

H. Evaluasi Model

Kinerja model dievaluasi menggunakan dataset uji yang benar-benar terpisah dari data pelatihan dan validasi. Tujuannya adalah mengukur sejauh mana model mampu mengenali dan mengklasifikasikan citra rontgen dada baru yang belum pernah dilihat selama proses pembelajaran.

Parameter evaluasi yang digunakan meliputi *accuracy*, *precision*, *recall*, dan F1-score untuk memberikan gambaran komprehensif tentang kinerja model. Berbagai metrik evaluasi digunakan untuk memastikan bahwa kinerja model diukur tidak hanya berdasarkan akurasi, tetapi juga berdasarkan keseimbangan kemampuan model dalam mengenali kelas-kelas individu.

Semua metrik evaluasi diterapkan secara konsisten pada kedua model, yaitu DenseNet121 dan DenseNet121 yang dikombinasikan dengan CBAM, menggunakan data uji yang sama untuk memastikan keadilan dan objektivitas dalam perbandingan kinerja.

Selain itu, kinerja model dianalisis lebih lanjut menggunakan confusion matrix untuk menentukan distribusi

prediksi benar dan salah untuk setiap kelas, yaitu kelas paru-paru normal dan kelas tuberkulosis (TBC). Confusion matrix digunakan untuk mengevaluasi kemampuan model dalam membedakan kedua kelas ini dengan lebih akurat.

Laporan klasifikasi (*classification report*) kemudian digunakan untuk menampilkan nilai precision, recall, dan F1-score untuk setiap kelas, yang dapat digunakan untuk menentukan keseimbangan kinerja model dalam mengidentifikasi rontgen paru-paru normal dan rontgen dengan tuberkulosis.

Selain metrik accuracy, precision, recall, dan F1-score, evaluasi tambahan dilakukan menggunakan Area Under the Receiver Operating Characteristic Curve (AUC-ROC) untuk memberikan gambaran yang lebih komprehensif tentang kemampuan model dalam membedakan kelas normal dan tuberkulosis. Nilai AUC-ROC berkisar antara 0 hingga 1, di mana nilai 1 menunjukkan kemampuan klasifikasi yang sempurna dan nilai 0,5 menunjukkan kemampuan klasifikasi yang setara dengan tebakan acak. Kurva ROC divisualisasikan untuk setiap model dan skenario pembagian data sebagaimana ditampilkan pada Gambar 4 dan 5.

I. Perbandingan Model

Langkah terakhir dalam penelitian ini adalah membandingkan kinerja model DenseNet121 dengan kinerja model DenseNet121 yang dikombinasikan dengan Convolutional Block Attention Module (CBAM) berdasarkan hasil evaluasi yang diperoleh. Perbandingan ini dilakukan menggunakan metrik evaluasi yang sama dan data uji yang identik untuk memastikan objektivitas hasil perbandingan. Perbandingan ini bertujuan untuk menganalisis dampak penerapan mekanisme perhatian CBAM dalam meningkatkan kemampuan model untuk mengekstrak fitur penting dari citra rontgen dada. Oleh karena itu, peningkatan kinerja model *DenseNet121* + CBAM dapat diinterpretasikan sebagai kontribusi mekanisme perhatian dalam meningkatkan akurasi dan konsistensi klasifikasi tuberkulosis paru.

III. HASIL DAN PEMBAHASAN

Bab ini memaparkan hasil dari seluruh rangkaian eksperimen yang telah dilaksanakan dalam penelitian, serta pembahasan mengenai kinerja model dalam mengklasifikasikan tuberkulosis paru berdasarkan citra rontgen dada. Hasil penelitian disajikan dalam bentuk grafik dan visualisasi pendukung untuk menggambarkan kinerja model secara objektif. Pembahasan merujuk pada hasil eksperimen terkait dengan metode yang digunakan, konsep-konsep relevan, dan penelitian sebelumnya.

A. Hasil Pelatihan Model

Hasil pelatihan model dalam penelitian ini dianalisis menggunakan grafik akurasi dan loss untuk data latih dan validasi. Analisis dilakukan untuk dua skenario pembagian data, yaitu skenario 60:20:20 dan skenario 70:15:15, untuk masing-masing arsitektur model yang digunakan, yaitu DenseNet121 dan DenseNet121 yang dikombinasikan dengan

Convolutional Block Attention Module (CBAM). Presentasi hasil pelatihan ini bertujuan untuk mengamati pola konvergensi, stabilitas proses pelatihan, dan perbedaan perilaku pembelajaran antara model-model tersebut sebelum dilakukan evaluasi kinerja yang lebih rinci.

1) *Skenario Pembagian Data 60:20:20*: Pada skenario pembagian data 60:20:20, dataset dibagi menjadi 60% data latih, 20% data validasi, dan 20% data uji. Skenario ini digunakan untuk mengevaluasi model dalam mempelajari pola dari jumlah data pelatihan yang relatif terbatas, sekaligus memantau stabilitas proses pelatihan berdasarkan kinerja pada data validasi. Proses pelatihan dilakukan selama 20 *epoch* dengan parameter yang sama untuk kedua arsitektur model, yaitu DenseNet121 dan DenseNet121 yang dikombinasikan dengan Convolutional Block Attention Module (CBAM).


Berdasarkan Gambar 6 yang menunjukkan perbandingan grafik akurasi dan loss untuk skenario pembagian data 60:20:20, dapat dilihat bahwa kedua model menunjukkan pola pembelajaran yang stabil selama proses pelatihan. Untuk model DenseNet121, grafik akurasi meningkat secara signifikan pada *epoch-epoch* awal dan kemudian stabil hingga akhir pelatihan. Grafik loss juga menunjukkan penurunan yang konsisten pada data latih dan validasi dengan penyimpangan yang relatif kecil, sehingga tidak ada tanda-tanda *overfitting* yang signifikan. Sementara itu, model DenseNet121 yang dikombinasikan dengan Convolutional Block Attention Module (CBAM) menunjukkan proses konvergensi yang lebih cepat dibandingkan model tanpa mekanisme perhatian. Grafik akurasi model DenseNet121 + CBAM mencapai nilai tinggi dalam jumlah *epoch* yang lebih sedikit, dengan selisih yang sangat kecil antara akurasi pelatihan dan validasi. Pada grafik loss, penurunan terjadi lebih cepat dan stabil, mencapai nilai yang sangat rendah pada *epoch* akhir. Perbandingan ini menunjukkan bahwa penambahan CBAM membantu model fokus pada ekstraksi fitur di area citra yang relevan, sehingga proses optimasi menjadi lebih efisien dan stabil dibandingkan dengan *DenseNet121* tanpa mekanisme perhatian.

Model DenseNet121 + CBAM pada skenario 60:20:20 mencapai akurasi validasi 100% dengan nilai *loss* validasi yang sangat rendah dan stabil pada *epoch-epoch* akhir, menunjukkan bahwa


model telah mencapai konvergensi optimal dalam 20 *epoch* pelatihan.

Secara kuantitatif, model DenseNet121 pada skenario 60:20:20 mencapai akurasi validasi

Grafik Akurasi dan Loss Model DenseNet121
Skenario Pembagian Data 60:20:20



Grafik Akurasi dan Loss Model DenseNet121 + CBAM
Skenario Pembagian Data 60:20:20



Gambar 6 Grafik akurasi dan loss model (atas) DenseNet121 dan (bawah) DenseNet121 + CBAM pada skenario pembagian data 60:20:20

sebesar 99% pada akhir pelatihan dengan nilai loss validasi yang menurun secara konsisten hingga mendekati 0. Hal ini mengkonfirmasi bahwa 20 epoch pelatihan sudah cukup untuk mencapai konvergensi yang stabil, didukung oleh penggunaan pendekatan transfer learning dengan bobot pre-trained ImageNet yang mempercepat proses pembelajaran dibandingkan pelatihan dari awal.

- 2) *Skenario Pembagian Data 70:15:15*: Pada skenario dengan pembagian data 70:15:15, dataset dibagi menjadi 70% data latih, 15% data validasi, dan 15% data uji. Proporsi data pelatihan yang lebih besar dalam skenario ini bertujuan untuk meningkatkan kemampuan model dalam mempelajari representasi fitur secara lebih optimal. Proses pelatihan dilakukan selama 20 epoch dengan konfigurasi dan parameter pelatihan yang sama seperti pada skenario sebelumnya, baik untuk model DenseNet121


maupun untuk model DenseNet121 yang dikombinasikan dengan CBAM.

Berdasarkan Gambar 7, grafik akurasi dan loss model DenseNet121 dengan skenario pembagian data 70:15:15 menunjukkan proses pelatihan yang stabil. Grafik akurasi menunjukkan peningkatan yang konsisten pada data latih dan validasi seiring bertambahnya jumlah epoch, dengan selisih antara keduanya relatif kecil. Pola tersebut mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik. Selain itu, grafik loss memperlihatkan penurunan yang stabil hingga mencapai kondisi relatif konvergen pada epoch-epoch akhir, yang menunjukkan bahwa proses optimasi berlangsung secara efektif tanpa


terjadinya overfitting yang signifikan.

Untuk model DenseNet121 yang digabungkan dengan Convolutional Block Attention Module (CBAM) dalam skenario pembagian data 70:15:15, grafik akurasi menunjukkan peningkatan yang lebih

Grafik Akurasi dan Loss Model DenseNet121
Skenario Pembagian Data 70:15:15



Grafik Akurasi dan Loss Model DenseNet121 + CBAM
Skenario Pembagian Data 70:15:15



Gambar 7 Grafik akurasi dan loss model (atas) DenseNet121 dan (bawah) DenseNet121 + CBAM pada skenario pembagian data 70:15:15

cepat pada fase pelatihan awal dan mencapai keadaan stabil lebih awal dibandingkan model tanpa mekanisme perhatian. Kesamaan nilai akurasi pada data pelatihan dan validasi mengindikasikan kestabilan proses pembelajaran model. Grafik loss menunjukkan penurunan yang lebih cepat dan halus, dengan nilai loss validasi mengikuti loss pelatihan tanpa fluktuasi signifikan. Temuan ini mengindikasikan bahwa integrasi CBAM memberikan dampak positif terhadap stabilitas serta performa proses pelatihan, khususnya ketika model dilatih menggunakan jumlah data pelatihan yang lebih besar.

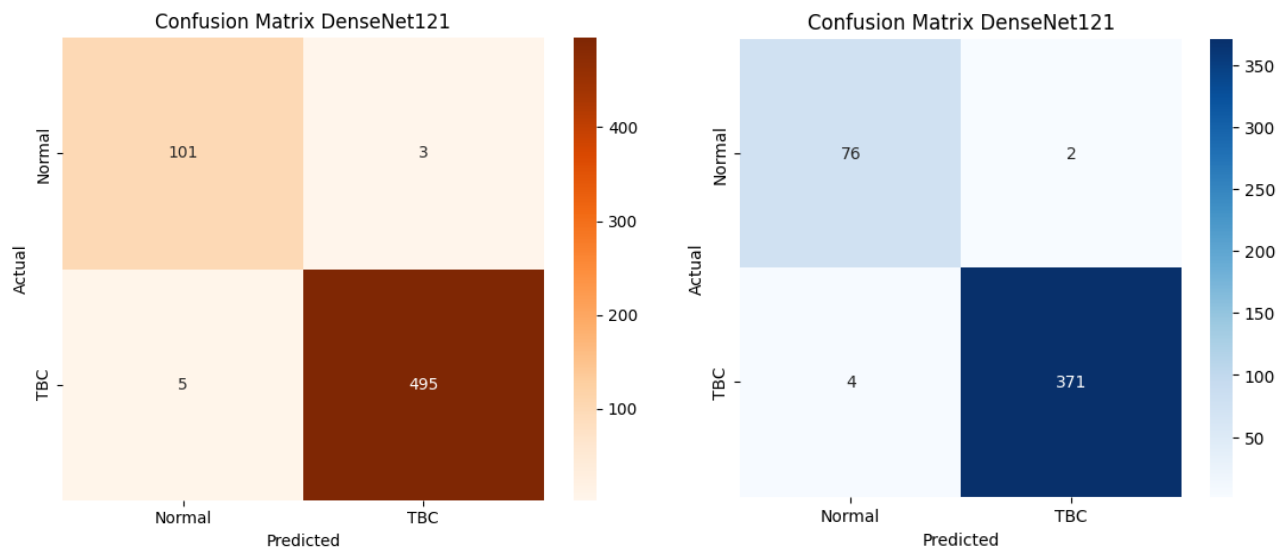
Secara kuantitatif, model DenseNet121+CBAM pada skenario 70:15:15 mencapai akurasi validasi 100% dengan nilai loss validasi yang sangat rendah dan stabil, mengkonfirmasi bahwa konvergensi optimal telah tercapai dalam 20 epoch pelatihan.

B. Hasil Evaluasi Model

Evaluasi kinerja model dilakukan untuk menilai kemampuannya dalam mengklasifikasikan citra rontgen dada

ke dalam dua kelas, yaitu normal dan tuberkulosis (TBC). Proses evaluasi menggunakan matriks kebingungan dan laporan klasifikasi yang mencakup metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Evaluasi diterapkan pada dua arsitektur model, yaitu *DenseNet121* dan *DenseNet121* yang dikombinasikan dengan *Convolutional Block Attention Module (CBAM)*, dengan dua skenario pembagian data, yaitu 60:20:20 dan 70:15:15.

Confusion matrix digunakan untuk mewakili distribusi prediksi model pada data aktual. Confusion matrix dapat digunakan untuk mengidentifikasi empat keadaan, yaitu True Positive (TP) ketika citra TBC diprediksi sebagai TBC, False Positive (FP) ketika citra Normal diprediksi sebagai TBC, False Negative (FN) ketika citra TBC diprediksi sebagai Normal, serta True Negative (TN) ketika citra Normal



Gambar 8 Confusion matrix model DenseNet121 pada (kiri) skenario pembagian data 60:20:20 dan (kanan) skenario 70:15:15

diprediksi sebagai Normal. Dalam konteks klinis, kesalahan FN pada kelas TBC sangat signifikan, karena dapat menyebabkan kasus tuberkulosis tidak terdeteksi.

- 1) *Evaluasi Model DenseNet121*: Model DenseNet121 dievaluasi untuk menganalisis kemampuannya dalam mengklasifikasikan citra rontgen dada ke dalam kategori normal dan tuberkulosis (TBC). Evaluasi ini dilakukan menggunakan confusion matrix pada dua skenario data, yaitu 60:20:20 dan 70:15:15, untuk menganalisis pola klasifikasi dan kesalahan prediksi yang terjadi.

Berdasarkan Gambar 8, pada skenario dengan pembagian data 60:20:20 menunjukkan bahwa model DenseNet121 dapat mengklasifikasikan sebagian besar data uji dengan benar. Sebagian besar citra dalam kelas Normal dan TBC diprediksi dengan benar, dengan jumlah kesalahan klasifikasi yang relatif rendah.

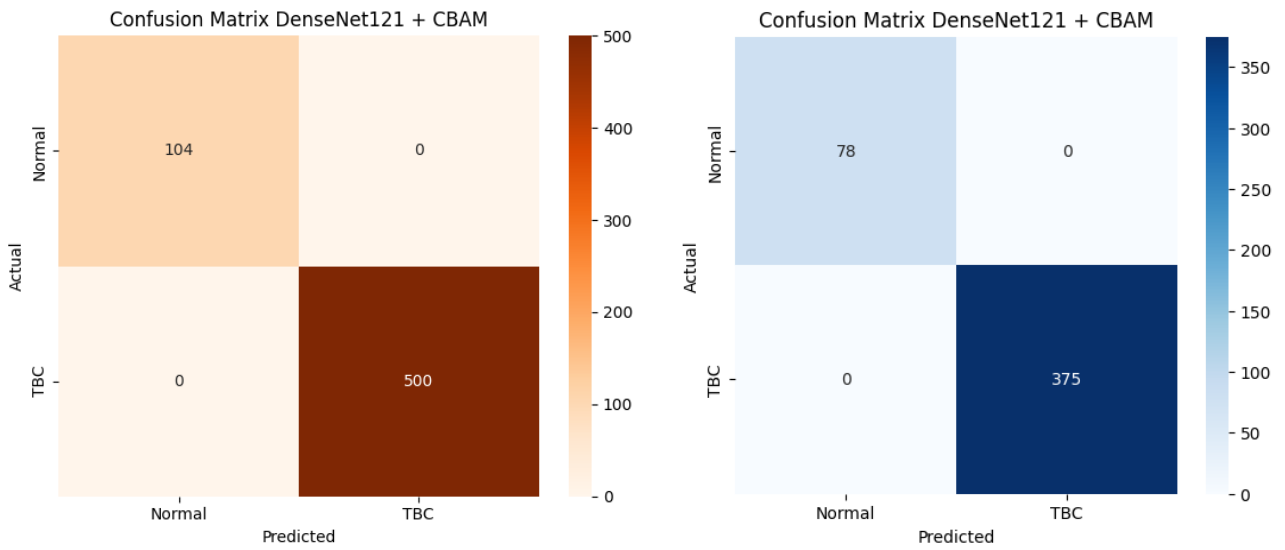
Kesalahan yang terjadi tidak mendominasi hasil klasifikasi, menunjukkan bahwa model memiliki kemampuan yang baik dalam membedakan antara kedua kelas. Khususnya pada kelas TBC, jumlah kesalahan False Negative sangat rendah, menunjukkan bahwa model memiliki sensitivitas yang baik dalam mendeteksi kasus tuberkulosis. Selanjutnya, pada skenario dengan pembagian data 70:15:15, kinerja model menunjukkan pola yang serupa dengan skenario sebelumnya. Hampir semua data uji dapat diklasifikasikan dengan benar, dengan tingkat kesalahan yang sangat rendah di kedua kelas. Konsistensi ini menunjukkan bahwa peningkatan proporsi data latih tidak memengaruhi kinerja model. Hasil menunjukkan bahwa DenseNet121 mempertahankan kemampuan generalisasi yang baik meskipun konfigurasi pembagian dataset berbeda.

- 2) *Evaluasi Model DenseNet121 + CBAM*: Evaluasi berikutnya dilakukan pada model DenseNet121 yang dikombinasikan dengan Convolutional Block Attention Module (CBAM). Penambahan

mekanisme perhatian ini bertujuan untuk meningkatkan kemampuan model dalam fokus pada fitur-fitur penting pada citra rontgen dada. Evaluasi dilakukan menggunakan dua skenario data yang sama, yaitu 60:20:20 dan 70:15:15.

Berdasarkan Gambar 9, confusion matrix pada skenario dengan pembagian data 60:20:20 menunjukkan bahwa tidak ditemukan kesalahan klasifikasi pada data uji, baik pada kelas Normal maupun kelas TBC. Tidak ada kesalahan False Positive maupun False Negative, sehingga semua citra dapat diklasifikasikan dengan benar. Hasil ini menunjukkan bahwa model DenseNet121 + CBAM sangat mampu membedakan antara kedua kelas tersebut. Integrasi Convolutional Block Attention Module (CBAM) membantu model mengekstrak fitur yang lebih diskriminatif dan relevan untuk karakteristik tuberkulosis paru.

Selanjutnya, pada skenario dengan pembagian data 70:15:15, hasil evaluasi yang ditampilkan dalam Tabel VII menunjukkan kinerja yang konsisten dengan skenario sebelumnya. Confusion matrix kembali menunjukkan bahwa tidak ada kesalahan klasifikasi untuk kedua kelas, normal atau TBC. Konsistensi ini menunjukkan bahwa model DenseNet121 + CBAM menunjukkan stabilitas kinerja yang sangat baik meskipun proporsi data pelatihan meningkat. Namun, kinerja yang sangat tinggi ini memerlukan validasi lebih lanjut menggunakan dataset eksternal untuk memastikan generalisasi model terhadap data klinis yang lebih beragam.



Gambar 9 Confusion matrix model DenseNet121 + CBAM pada (kiri) skenario pembagian data 60:20:20 dan (kanan) skenario 70:15:15

Pada Tabel II merangkum nilai precision, recall, dan F1-score per kelas untuk setiap model dan skenario pembagian data yang digunakan dalam penelitian ini. Berdasarkan tabel tersebut, model DenseNet121 pada kedua skenario menunjukkan nilai precision, recall, dan F1-score sebesar 0.95, 0.97, dan 0.96 untuk kelas Normal, serta 0.99, 0.99, dan 0.99 untuk kelas TBC. Hal ini merupakan aspek penting dalam konteks klinis, karena kegagalan mendeteksi kasus TBC dapat memiliki implikasi serius bagi diagnosis dan pengobatan pasien. Sementara itu, model DenseNet121 +

CBAM berhasil mencapai nilai sempurna sebesar 1.00 untuk seluruh metrik pada kedua kelas di kedua skenario pembagian data. Hal ini menunjukkan bahwa integrasi CBAM tidak hanya meningkatkan performa pada kelas TBC, tetapi juga meningkatkan kemampuan model dalam mengklasifikasikan kelas Normal secara lebih akurat dibandingkan DenseNet121 tanpa mekanisme perhatian.

TABEL II
HASIL EVALUASI MODEL PER KELAS PADA SKENARIO PEMBAGIAN DATA 60:20:20 DAN 70:15:15

Model	Split Data	Accuracy	Precision Normal	Recall Normal	F1 Normal	Precision TBC	Recall TBC	F1 TBC
DenseNet121	60:20:20	0.99	0.95	0.97	0.96	0.99	0.99	0.99
DenseNet121	70:15:15	0.99	0.95	0.97	0.96	0.99	0.99	0.99
DenseNet121 + CBAM	60:20:20	1.00	1.00	1.00	1.00	1.00	1.00	1.00
DenseNet121 + CBAM	70:15:15	1.00	1.00	1.00	1.00	1.00	1.00	1.00

C. Perbandingan Kinerja Model

Dalam penelitian ini, dilakukan perbandingan kinerja antara model DenseNet121 dan DenseNet121 yang dikombinasikan dengan Convolutional Block Attention Module (CBAM) pada dua skenario data, yaitu 60:20:20 dan 70:15:15. Perbandingan ini bertujuan untuk mengevaluasi stabilitas model, pengaruh penerapan mekanisme perhatian, dan kemampuan model dalam mendeteksi citra tuberkulosis paru.

Berdasarkan hasil evaluasi, model DenseNet121 tanpa CBAM menunjukkan kinerja yang sangat baik, dengan akurasi 99% pada kedua skenario data. Nilai precision, recall, dan F1-score pada kelas TBC juga tinggi, menunjukkan bahwa model mampu mengklasifikasikan citra TBC dengan

akurat dan konsisten meskipun terdapat perbedaan rasio antara data pelatihan dan data uji.

Selain itu, penerapan CBAM pada arsitektur DenseNet121 menghasilkan peningkatan kinerja yang signifikan. Model DenseNet121 + CBAM mencapai akurasi 100% dan nilai precision, recall, dan F1-score sebesar 1.00 pada kedua skenario data. Peningkatan tersebut mengindikasikan bahwa mekanisme perhatian CBAM mampu mengarahkan model untuk lebih berfokus pada proses ekstraksi fitur pada area-area penting citra rontgen dada yang berkaitan dengan karakteristik tuberkulosis paru.

Jika ditinjau dari metrik recall kelas TBC, yang merupakan metrik paling penting dalam konteks diagnosis medis, model DenseNet121 + CBAM berkinerja lebih baik daripada DenseNet121 tanpa CBAM. Recall sempurna menunjukkan

bahwa model dengan CBAM mampu meminimalkan kesalahan False Negative, sehingga semua kasus TBC dalam data uji terdeteksi dengan benar.

Selain itu, hasil evaluasi pada dua skenario pembagian data menunjukkan bahwa model DenseNet121 + CBAM memiliki stabilitas dan kemampuan generalisasi yang lebih baik, sebagaimana dibuktikan oleh konsistensi nilai metrik evaluasi, yang tidak menurun meskipun proporsi data pelatihan dan uji berbeda. Hal ini menunjukkan bahwa penggunaan CBAM tidak hanya meningkatkan akurasi model, tetapi juga membantu mengurangi ketergantungan model pada konfigurasi data spesifik.

Secara keseluruhan, dapat disimpulkan bahwa penambahan CBAM pada arsitektur DenseNet121 secara efektif meningkatkan kinerja klasifikasi rontgen dada, terutama dalam deteksi kasus tuberkulosis, dan menghasilkan model yang lebih stabil dan andal. Oleh karena itu, DenseNet121 + CBAM tidak hanya unggul dalam hal akurasi, tetapi juga menawarkan potensi yang lebih baik untuk digunakan dalam sistem diagnostik klinis yang memerlukan sensitivitas tinggi terhadap penyakit.

Sebagai pembanding tambahan, model ResNet50 juga dilatih menggunakan konfigurasi dan dataset yang sama untuk mengevaluasi keunggulan arsitektur DenseNet121 dan DenseNet121+CBAM. Hasil evaluasi menunjukkan bahwa ResNet50 hanya mampu mencapai akurasi sebesar 83% pada kedua skenario pembagian data, dengan nilai AUC-ROC sebesar 0.9360 pada skenario 60:20:20 dan 0.9284 pada skenario 70:15:15. Lebih lanjut, analisis classification report menunjukkan bahwa ResNet50 gagal mendeteksi kelas Normal secara keseluruhan, dengan nilai precision, recall, dan F1-score sebesar 0.00 pada kelas Normal di kedua skenario. Kondisi ini mengindikasikan bahwa ResNet50 cenderung memprediksi seluruh citra sebagai kelas TBC akibat ketidakseimbangan distribusi kelas pada dataset yang digunakan.

Perbandingan ini menunjukkan bahwa arsitektur DenseNet121 dengan pendekatan transfer learning memiliki kemampuan yang lebih baik dalam menangani ketidakseimbangan kelas dibandingkan ResNet50, sebagaimana dibuktikan oleh pencapaian akurasi 99% pada DenseNet121 dan 100% pada DenseNet121 + CBAM. Selain itu, nilai AUC-ROC DenseNet121 (0.9992 dan 0.9993) dan DenseNet121+CBAM (1.0000) jauh lebih tinggi dibandingkan ResNet50 (0.9360 dan 0.9284), menegaskan keunggulan arsitektur DenseNet121 dalam tugas klasifikasi tuberkulosis paru berbasis citra rontgen dada.

Ditinjau dari perbandingan antar skenario pembagian data, hasil evaluasi menunjukkan konsistensi kinerja yang sangat tinggi antara skenario 60:20:20 dan 70:15:15 pada kedua model. Model DenseNet121 secara konsisten mencapai akurasi 99% pada kedua skenario, sedangkan model DenseNet121+CBAM secara konsisten mencapai akurasi 100% pada kedua skenario. Konsistensi ini mengindikasikan bahwa perbedaan proporsi data pelatihan dan pengujian antara kedua skenario tidak memberikan pengaruh yang

signifikan terhadap kinerja model. Hal ini menunjukkan bahwa model yang dikembangkan memiliki stabilitas dan kemampuan generalisasi yang baik, sehingga tidak bergantung pada konfigurasi pembagian data tertentu. Dengan demikian, dapat disimpulkan bahwa kinerja model bersifat stabil dan konsisten meskipun proporsi data pelatihan ditingkatkan dari 60% menjadi 70%, yang mengindikasikan bahwa model telah mencapai kapasitas pembelajaran optimal bahkan dengan jumlah data pelatihan yang lebih sedikit.

D. Pembahasan

Hasil penelitian menunjukkan bahwa model *DenseNet121* yang dikombinasikan dengan *Convolutional Block Attention Module (CBAM)* menghasilkan kinerja yang lebih baik dibandingkan *DenseNet121* tanpa mekanisme perhatian pada seluruh skenario pembagian data. Peningkatan ini dapat dijelaskan oleh konsep *mekanisme perhatian*, yang memungkinkan model untuk memfokuskan proses ekstraksi fitur pada area citra yang paling relevan dengan tugas klasifikasi.

CBAM mengintegrasikan Channel Attention dan Spatial Attention pada feature map hasil ekstraksi convolution. Channel attention membantu model menyoroti fitur penting antar kanal, sementara Spatial Attention mengarahkan perhatian ke lokasi spasial spesifik dalam citra. Dalam konteks citra rontgen dada, mekanisme ini memungkinkan model menyoroti area paru-paru dengan pola abnormal, seperti opasitas atau infiltrat, yang khas untuk tuberkulosis paru. Hal ini menjelaskan mengapa model DenseNet121 + CBAM mampu meningkatkan nilai recall kelas TBC dan meminimalkan kesalahan False Negative.

Selain meningkatkan fokus pada fitur penting, mekanisme perhatian CBAM juga membantu mempercepat proses konvergensi selama pelatihan, karena model belajar representasi fitur yang relevan secara lebih efisien dan mengurangi pembelajaran noise yang tidak terkait dengan wilayah paru-paru.

Meskipun hasil evaluasi menunjukkan kinerja sempurna pada data uji, validasi lebih lanjut dengan dataset eksternal diperlukan untuk memastikan generalisasi model pada data klinis yang lebih beragam.

Temuan ini sejalan dengan berbagai penelitian terdahulu yang melaporkan bahwa penerapan mekanisme perhatian pada jaringan convolutional mampu meningkatkan performa klasifikasi citra medis. Penelitian sebelumnya menunjukkan bahwa CBAM secara efektif meningkatkan representasi fitur dengan menekan noise latar belakang dan menonjolkan area patologis yang relevan, sehingga meningkatkan sensitivitas model terhadap kelas penyakit. Oleh karena itu, hasil penelitian ini mengonfirmasi temuan sebelumnya bahwa mekanisme perhatian memberikan kontribusi positif pada sistem klasifikasi berbasis citra untuk rontgen dada.

Meskipun menghasilkan kinerja yang sangat baik, penelitian ini masih memiliki beberapa keterbatasan. Pertama, dataset yang digunakan menunjukkan ketidakseimbangan antara jumlah data di setiap kelas, dengan

jumlah gambar TBC yang lebih banyak dibandingkan kelas normal. Kondisi ini berpotensi memengaruhi nilai metrik evaluasi, terutama akurasi, sehingga evaluasi difokuskan pada metrik recall yang secara klinis lebih relevan untuk kelas TBC.

Recall kelas TBC merupakan metrik yang lebih penting daripada akurasi, karena kesalahan False Negative pada kasus tuberkulosis dapat memiliki konsekuensi klinis yang serius, yaitu pasien yang sebenarnya terinfeksi terlewatkan.

Kedua, studi ini hanya mempertimbangkan dua kelas klasifikasi, yaitu normal dan tuberkulosis. Dalam praktik klinis, rontgen dada dapat menunjukkan berbagai penyakit paru lainnya, seperti pneumonia atau kanker paru, yang tidak dipertimbangkan dalam studi ini. Oleh karena itu, generalisasi model dalam skenario multi-kelas perlu dievaluasi lebih lanjut.

Ketiga, tidak dilakukan segmentasi paru sebelum proses klasifikasi dalam penelitian ini. Tanpa segmentasi, ada kemungkinan model akan belajar fitur dari area non-paru seperti tulang rusuk atau jaringan sekitar, yang dapat mengganggu proses pembelajaran. Penambahan segmentasi paru bertujuan untuk meningkatkan fokus model pada area anatomi yang relevan dan mengoptimalkan kinerja klasifikasi.

Sebagai arah penelitian lebih lanjut, disarankan untuk menggunakan dataset yang lebih seimbang, memperluas skenario klasifikasi ke kelas-kelas multiple, dan menggabungkan mekanisme perhatian dengan metode segmentasi paru-paru untuk mendapatkan sistem klasifikasi yang lebih robust untuk tuberkulosis paru yang lebih dekat dengan kondisi klinis sebenarnya.

Selain itu, hasil perbandingan skenario data menunjukkan bahwa meningkatkan proporsi data pelatihan dari 60% menjadi 70% tidak secara signifikan meningkatkan kinerja, menunjukkan bahwa model telah mencapai kapasitas pembelajaran optimalnya pada skenario sebelumnya.

Selain aspek teknis, penerapan sistem klasifikasi berbasis deep learning dalam konteks medis juga perlu mempertimbangkan aspek etika dan implikasi klinis. Sistem yang dikembangkan dalam penelitian ini dirancang sebagai sistem pendukung keputusan (decision support system), bukan sebagai pengganti diagnosis oleh tenaga medis profesional. Hasil prediksi model harus selalu diinterpretasikan dan divalidasi oleh dokter atau radiolog sebelum digunakan sebagai dasar pengambilan keputusan klinis. Hal ini penting mengingat bahwa meskipun model mencapai performa yang sangat tinggi pada dataset uji, generalisasi model pada kondisi klinis nyata yang lebih beragam masih memerlukan validasi lebih lanjut. Selain itu, penggunaan dataset publik yang telah mendapatkan lisensi Creative Commons Attribution-ShareAlike 4.0 memastikan bahwa penelitian ini dilakukan sesuai dengan prinsip etika penelitian yang berlaku. Kedepannya, implementasi sistem ini dalam lingkungan klinis nyata perlu mempertimbangkan aspek privasi data pasien, regulasi penggunaan AI dalam

bidang kesehatan, serta transparansi model agar dapat diterima dan dipercaya oleh tenaga medis.

IV. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem untuk mengklasifikasikan tuberkulosis paru berdasarkan citra rontgen dada, menggunakan arsitektur DenseNet121 dan DenseNet121 bersama dengan Convolutional Block Attention Module (CBAM). Model dikembangkan menggunakan pendekatan transfer learning dan dievaluasi pada dua skenario pembagian data, yaitu 60:20:20 dan 70:15:15, untuk mengevaluasi konsistensi kinerja dengan proporsi data pelatihan dan pengujian yang berbeda.

Hasil eksperimen menunjukkan bahwa model DenseNet121 tanpa mekanisme perhatian mencapai kinerja klasifikasi yang sangat baik dengan akurasi 99% pada kedua skenario data. Namun, penambahan CBAM ke arsitektur DenseNet121 menyebabkan peningkatan signifikan dalam kinerja model. Model DenseNet121 + CBAM berhasil mencapai nilai akurasi, precision, recall, dan F1-score sebesar 1.00 dalam semua skenario data yang diuji, tanpa ditemukan False Positive atau False Negative pada data uji.

Peningkatan kinerja ini menunjukkan bahwa mekanisme perhatian CBAM secara efektif membantu model memfokuskan proses ekstraksi fitur pada area relevan di paru-paru, sehingga meningkatkan sensitivitas model dalam mendeteksi kasus tuberkulosis. Hal ini sangat penting dalam konteks klinis, karena False Negative pada kasus tuberkulosis dapat memiliki implikasi serius bagi diagnosis dan pengobatan pasien.

Namun, penelitian ini masih memiliki beberapa keterbatasan yang perlu ditindaklanjuti dalam penelitian selanjutnya. Pertama, dataset yang digunakan menunjukkan ketidakseimbangan antara jumlah data di setiap kelas, dengan jumlah citra TBC yang lebih banyak dibandingkan kelas normal. Kedua, penelitian ini hanya mempertimbangkan dua kelas klasifikasi yaitu normal dan tuberkulosis, sementara dalam praktik klinis rontgen dada dapat menunjukkan berbagai penyakit paru lainnya seperti pneumonia atau kanker paru. Ketiga, tidak diterapkannya segmentasi paru sebelum proses klasifikasi, sehingga ada kemungkinan model mempelajari fitur dari area non-paru yang dapat mengganggu proses pembelajaran. Keempat, evaluasi model hanya dilakukan pada dataset internal sehingga validasi menggunakan dataset eksternal dari institusi atau wilayah geografis yang berbeda masih diperlukan untuk memastikan kemampuan generalisasi model pada data klinis yang lebih beragam. Kelima, penelitian ini belum mengimplementasikan teknik interpretabilitas model seperti Gradient-weighted Class Activation Mapping (Grad-CAM) yang dapat memvisualisasikan area paru-paru yang menjadi fokus perhatian model dalam proses klasifikasi. Oleh karena itu, untuk penelitian lebih lanjut disarankan untuk menggunakan dataset yang lebih seimbang dan beragam, menerapkan klasifikasi multi-kelas, menggabungkan mekanisme perhatian dengan metode segmentasi paru, melakukan

validasi eksternal menggunakan dataset dari sumber yang berbeda, serta mengimplementasikan Grad-CAM untuk meningkatkan transparansi dan kepercayaan model dalam konteks klinis.

Secara umum, hasil penelitian mengungkapkan bahwa integrasi modul Convolutional Block Attention Module (CBAM) pada arsitektur DenseNet121 memiliki potensi besar untuk digunakan sebagai sistem pendukung diagnosis tuberkulosis paru berdasarkan rontgen dada.

DAFTAR PUSTAKA

- [1] A. Rasyid and L. Heryawan, "Klasifikasi Penyakit Tuberculosis (TB) Organ Paru Manusia Berdasarkan Citra Rontgen Thorax Menggunakan Metode Convolutional Neural Network (CNN)," *Jurnal Manajemen Informasi Kesehatan Indonesia (JMiki)*, vol. 11, no. 1, Mar. 2023, doi: 10.33560/jmiki.v11i1.484.
- [2] M. B. Sastramandala, R. N. Sari, and N. Novrina, "Pemanfaatan Deep Learning menggunakan Convolutional Neural Network Terhadap Penyakit Tuberculosis melalui Citra Rontgen," *Jurnal Minfo Polgan*, vol. 14, no. 1, pp. 631–642, May 2025, doi: 10.33395/jmp.v14i1.14818.
- [3] S. Iqbal, A. N. Qureshi, J. Li, and T. Mahmood, "On the Analyses of Medical Images Using Traditional Machine Learning Techniques and Convolutional Neural Networks," *Archives of Computational Methods in Engineering*, vol. 30, no. 5, pp. 3173–3233, Jun. 2023, doi: 10.1007/s11831-023-09899-9.
- [4] 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 Engineering Journal*, vol. 64, pp. 923–935, Feb. 2023, doi: 10.1016/j.aej.2022.10.053.
- [5] B. S. Nusantara and M. Akbar, "Klasifikasi Penyakit Tuberculosis Berdasarkan Citra Rontgen Thorax Menggunakan Multi-Scale Convolutional Neural Network," *sudo Jurnal Teknik Informatika*, vol. 3, no. 1, pp. 1–8, May 2024, doi: 10.56211/sudo.v3i1.483.
- [6] F. Shahira, B. S. Negara, F. Yanto, and S. Sanjaya, "Optimasi Hyperparameter Deep Learning untuk Deteksi X-Ray Paru-Paru Menggunakan Bayesian Optimization," *JIEET (Journal Information Engineering and Educational Technology)*, vol. 9, no. 1, pp. 56–63, 2025.
- [7] 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.
- [8] R. K. Pasha and K. Budiman, "Optimasi Model CNN Berbasis Transfer Learning Untuk Klasifikasi Pneumonia pada Citra X-Ray Dada," *SMATIKA JURNAL*, vol. 15, no. 01, pp. 167–178, Jun. 2025, doi: 10.32664/smatika.v15i01.1985.
- [9] J. Devasia, H. Goswami, S. Lakshminarayanan, M. Rajaram, and S. Adithan, "Deep learning classification of active tuberculosis lung zones wise manifestations using chest X-rays: a multi label approach," *Sci. Rep.*, vol. 13, no. 1, Dec. 2023, doi: 10.1038/s41598-023-28079-0.
- [10] S. Hansun, A. Argha, S. T. Liaw, B. G. Celler, and G. B. Marks, "Machine and Deep Learning for Tuberculosis Detection on Chest X-Rays: Systematic Literature Review," *J. Med. Internet Res.*, vol. 25, 2023, doi: 10.2196/43154.
- [11] O. Rochmawanti, F. Utaminigrum, and F. A. Bachtiar, "Analisis Performa Pre-Trained Model Convolutional Neural Network Dalam Mendeteksi Penyakit Tuberculosis," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIIK)*, vol. 8, pp. 805–814, Aug. 2021, doi: 10.25126/jtiik.202184441.
- [12] F. A. P. R. Putri, J. P. Tanjung, and N. P. Dharshini, "Implementation of Transfer Learning on CNN using DenseNet121 and ResNet50 for Brain Tumor Classification," *JITE (Journal of Informatics and Telecommunication Engineering)*, vol. 8, no. 2, pp. 325–334, Jan. 2025, doi: 10.31289/jite.v8i2.13952.
- [13] C. Halim, N. Geordie, E. Putra, N. A. Nugroho, and D. Suhartono, "Chest X-ray Image Classification to Identify Lung Diseases Using Convolutional Neural Network and Convolutional Block Attention Module," *INTERNATIONAL JOURNAL ON INFORMATICS VISUALIZATION*, vol. 7, no. 3, pp. 651–658, Sep. 2023, [Online]. Available: www.joiv.org/index.php/joiv
- [14] V. Sharma, Nillmani, S. K. Gupta, and K. K. Shukla, "Deep learning models for tuberculosis detection and infected region visualization in chest X-ray images," *Intelligent Medicine*, vol. 4, no. 2, pp. 104–113, May 2024, doi: 10.1016/j.imed.2023.06.001.
- [15] Q. Said, I. Ernawati, M. Mega Santoni, and J. R. Fatmawati, "Identifikasi Tuberculosis Paru Berdasarkan Foto Sinar-X Thorax Menggunakan Jaringan Syaraf Tiruan Backpropagation," *JURNAL INFORMATIK*, vol. 17, no. 1, pp. 27–37, 2021.
- [16] D. Kurniawan, M. Wahyudi, L. Pujiastuti, U. Bina Sarana Informatika, and S. Antar Bangsa, "Deteksi dan Prediksi Cerdas Penyakit Paru-Paru dengan Algoritma Random Forest," *Indonesian Journal Computer Science*, vol. 3, no. 1, pp. 51–56, 2024.
- [17] E. Çalli, E. Sogancioglu, B. van Ginneken, K. G. van Leeuwen, and K. Murphy, "Deep learning for chest X-ray analysis: A survey," *Med. Image Anal.*, vol. 72, p. 102125, Aug. 2021, doi: 10.1016/j.media.2021.102125.