

Deteksi Penyakit Paru-Paru Berdasarkan Gambar Citra X-Ray Menggunakan Arsitektur Convolutional Neural Network (Arsitektur Mobilenetv2)

Rizky Syaifurrahman*, Esi Putri Silmina

Program Studi Teknologi Informasi, Fakultas Sains dan Teknologi, Universitas 'Aisyiyah Yogyakarta, Yogyakarta, Indonesia

Email: ^{1,*}riezkylians@gmail.com, ²esiputrisilmina@unisayogya.ac.id

Email Penulis Korespondensi: riezkylians@gmail.com

Submitted: 28/05/2025; Accepted: 22/06/2025; Published: 23/06/2025

Abstrak—Paru-paru adalah organ vital dalam sistem pernapasan yang berfungsi untuk pertukaran gas antara oksigen dan karbon dioksida. Namun, kualitas udara yang tercemar dapat menyebabkan berbagai masalah kesehatan, termasuk penyakit paru-paru seperti pneumonia, pneumothorax, kanker paru-paru, dan tuberculosis. Penelitian ini bertujuan untuk mengembangkan model deteksi otomatis menggunakan arsitektur dari *Convolutional Neural Network* (CNN) yaitu MobileNetV2 untuk mengklasifikasikan citra *X-Ray* dari empat kelas penyakit paru-paru dan satu kelas paru-paru normal. *Dataset* yang digunakan terdiri dari 2500 gambar yang terbagi menjadi lima kelas, dengan pembagian 80% untuk pelatihan, 10% untuk validasi, dan 10% untuk pengujian. Proses *preprocessing* mencakup *resizing* gambar menjadi 224x224 *pixel*, normalisasi nilai *pixel*, dan teknik augmentasi untuk meningkatkan variasi data. Model yang dihasilkan menunjukkan performa yang baik, dengan akurasi pelatihan mencapai 98,76% dan akurasi validasi sebesar 97,20%. Evaluasi menggunakan *confusion matrix* menghasilkan nilai *F1-score* keseluruhan sebesar 0,94, dengan nilai tertinggi 0,98 pada kelas pneumothorax. Hasil ini menunjukkan bahwa model mampu mendeteksi dan mengklasifikasikan penyakit paru-paru secara akurat, dengan akurasi keseluruhan mencapai 94,40%. Penelitian ini memberikan kontribusi signifikan dalam pengembangan sistem deteksi otomatis penyakit paru-paru yang dapat diimplementasikan dalam aplikasi berbasis *website* atau *mobile*, serta menunjukkan performa yang baik di setiap kelas.

Kata Kunci: Convolutional Neural Network; MobileNetV2; Deteksi Penyakit Paru-paru; Citra X-Ray; Pembelajaran Mendalam

Abstract—The lungs are vital organs in the respiratory system that exchange gases, such as oxygen and carbon dioxide. However, poor air quality can lead to health problems, including lung diseases such as pneumonia, pneumothorax, lung cancer, and tuberculosis. The objective of this study is to develop an automatic detection model that uses the Convolutional Neural Network (CNN) architecture, specifically MobileNetV2, to classify X-ray images into five categories: four types of lung disease and normal lungs. The dataset consists of 2,500 images, which are divided into five classes: 80% for training, 10% for validation, and 10% for testing. Preprocessing includes resizing images to 224 x 224 pixels, normalizing pixel values, and using augmentation techniques to increase data variation. The resulting model demonstrated good performance, achieving a training accuracy of 98.76% and a validation accuracy of 97.20%. Evaluation using a confusion matrix yielded an overall F1 score of 0.94, with the highest value of 0.98 for pneumothorax. These results suggest that the model can accurately detect and classify lung diseases with an overall accuracy of 94.4%. This research significantly contributes to developing an automated lung disease detection system that can be implemented in web- or mobile-based applications and performs well across all classes.

Keywords: Convolutional Neural Network; MobileNetV2; Lung Disease Detection; X-Ray Images; Deep Learning

1. PENDAHULUAN

Paru-paru merupakan salah satu organ didalam tubuh yang sangat penting sistem pernapasan, dimana paru-paru merupakan tempat proses untuk pertukaran antara oksigen dengan karbon dioksida. Permasalahan yang sering terjadi dalam sistem pernapasan adalah dengan kualitas udara yang telah tercemar dan banyak mengandung bakteri. Masalah yang berada pada sistem pernapasan terutama di dalam paru-paru maka proses bernafas pun akan mengalami gangguan yang menyebabkan adanya kesulitan bernafas, kesulitan beraktivitas, dan bahkan dapat mengalami kekurangan oksigen yang bisa berakibat fatal. Adapun penyakit paru-paru yang banyak diderita oleh masyarakat diantaranya *pneumonia*, *pneumothorax*, kanker paru-paru dan *tuberculosis* [2] [3]. *Pneumonia* sendiri menjadi salah satu penyakit dengan angka kasus yang cukup tinggi mencapai 1.127.113 kasus pada tahun 2023, sementara penyakit *tuberculosis* dengan kasus cukup tinggi 638.646 kasus [3].

Berbagai metode dapat digunakan untuk melakukan identifikasi kelainan pada organ dalam seperti *Computerized Tomography Scan* (CT-Scan), *Magnetic Resonance Imaging* (MRI) dan foto rontgen (*X-Ray*). Salah satu dari berbagai metode tersebut *X-Ray* atau foto rontgen merupakan metode yang sering digunakan dalam melakukan identifikasi, namun dalam hal pembacaan foto rontgen yang masih secara manual oleh para dokter ahli yang dapat memakan waktu cukup lama dan dapat menghasilkan data deteksi yang subjektif [4]. Deteksi yang subjektif tersebut dikarenakan adanya keterbatasan para ahli dokter sebagai manusia yang memiliki keterbatasan dan tergantung akan pencahayaan dalam melakukan deteksi [5], oleh karena itu, diperlukannya sebuah pengembangan model yang dapat membantu dokter dalam deteksi penyakit pada paru-paru secara otomatis.

Kemajuan teknologi saat ini memungkinkan pemanfaatan dan implementasi dalam bidang medis dan kesehatan. Berbagai inovasi, seperti *Artificial Intelligence* (AI) dan *deep learning*, telah muncul sebagai teknik komputasi yang signifikan dalam bidang *Machine Learning* (ML) [6]. *Deep Learning* sendiri merupakan jaringan saraf tiruan untuk memecahkan suatu permasalahan dengan kumpulan data yang besar [7]. Salah satu bentuk dari

Deep Learning yang sering dimanfaatkan untuk sebuah klasifikasi gambar di bidang kesehatan adalah *Convolutional Neural Network (CNN)*.

Convolutional Neural Network sendiri merupakan salah satu dari beberapa jenis *Neural Network* ataupun jaringan saraf tiruan yang dapat digunakan untuk mengolah data dua dimensi [8]. Data dua dimensi tersebut seperti data gambar, video, teks, atau audio, dan khususnya efektif dalam mendiagnosis kondisi medis melalui analisis data berbasis gambar seperti *X-Ray* [9]. Kelebihan CNN lainnya yaitu dengan adanya fitur ekstraksi secara otomatis tanpa memerlukan fitur manual yang dirancang oleh manusia, sehingga dapat melakukan identifikasi fitur-fitur yang ada di dalam data visual atau gambar citra *X-Ray* [7]. CNN memiliki banyak sekali arsitektur antara lain *ResNet50V2*, *InceptionV3*, *InceptionResNetV2*, *VGG16*, *VGG19* [10], dan *MobileNetV2* [11]. Salah satu dari berbagai arsitektur CNN yang sering digunakan untuk melakukan penelitian ialah *MobileNetV2*. Penggunaan arsitektur *MobileNet*, dikarenakan memiliki cukup beberapa kelebihan salah satunya yaitu waktu dalam pelatihan model yang cukup cepat dibandingkan dengan model lain seperti penelitian yang dilakukan peneliti [2]. *MobileNet* sendiri merupakan salah satu dari sekian banyak arsitektur yang dapat digunakan pada aplikasi *mobile* [12].

Banyak penelitian serupa telah dilakukan untuk klasifikasi penyakit paru-paru menggunakan CNN, mendapatkan nilai akurasi yang cukup baik yaitu 87.88% yang dilakukan pada penelitian [13]. Akan tetapi model ini memiliki kekurangan dimana hanya menggunakan 98 gambar rontgen sebagai *dataset*. Penelitian lain yang berhasil mendapatkan nilai akurasi sebesar 91% dengan empat kelas klasifikasi yaitu, *pneumonia*, *covid-19*, *normal*, dan *tuberculocis* [14].

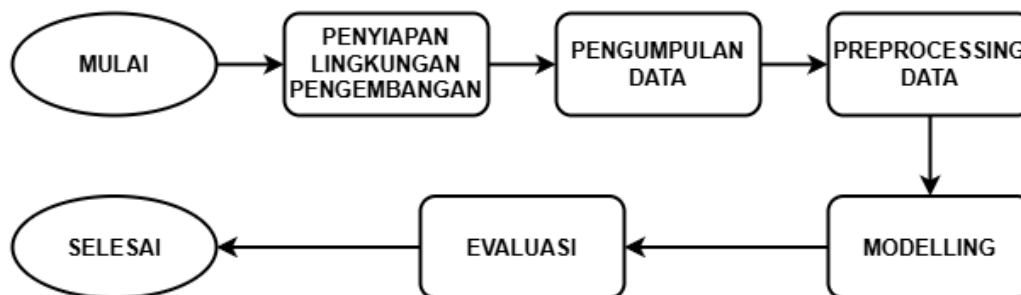
Penelitian serupa untuk klasifikasi penyakit paru-paru menggunakan arsitektur *MobileNet* mendapatkan nilai akurasi dengan rata-rata sebesar 98,69%, dimana pada penelitian tersebut menggunakan dua kelas klasifikasi penyakit yaitu *normal* dan *tuberculocis*[15]. Penelitian lain, menggunakan arsitektur *MobileNetV2* untuk deteksi penyakit kanker darah mendapatkan nilai akurasi sebesar 95,6% dengan empat klasifikasi, Empat klasifikasi tersebut berupa jenis-jenis kanker darah seperti *benign*, *early*, *pre*, dan *pro* [16]. Penelitian selanjutnya untuk klasifikasi penyakit paru-paru dengan empat kelas yaitu, *pneumonia*, *Coronavirus Disease-19 (Covid-19)*, dan *normal*, dengan nilai akurasi yang tinggi yaitu 95% [17].

Tujuan dari penelitian ini adalah mengklasifikasikan empat jenis penyakit paru-paru, yaitu *pneumonia*, *pneumotoraks*, *tuberkulosis*, dan kanker paru-paru dengan satu kelas *normal*, berdasarkan citra *X-Ray* dada menggunakan model arsitektur *MobileNetV2*. Berbeda dengan penelitian-penelitian sebelumnya yang umumnya hanya berfokus pada satu atau dua jenis penyakit paru-paru tertentu, penelitian ini secara langsung menggabungkan empat kategori penyakit dan *normal* dalam satu model klasifikasi multi-kelas. Penelitian terdahulu masih banyak menggunakan arsitektur jaringan konvolusional yang membutuhkan sumber daya komputasi tinggi, sedangkan penelitian ini menggunakan arsitektur *MobileNetV2* dikenal dengan lebih ringan dan efisien, sehingga lebih cocok untuk diterapkan pada perangkat dengan keterbatasan komputasi seperti aplikasi berbasis *website* atau *mobile*.

Evaluasi kinerja model dilakukan menggunakan metrik akurasi, *recall*, *precision*, dan *F1-score* untuk memastikan performa klasifikasi yang seimbang. Diharapkan, hasil dari penelitian ini dapat dikembangkan lebih lanjut menjadi sebuah sistem pendeteksi otomatis berbasis *website* maupun aplikasi *mobile* yang mendukung proses *skrining* awal penyakit paru-paru secara cepat, mudah, dan terjangkau, khususnya di wilayah dengan keterbatasan akses terhadap tenaga medis spesialis.

2. METODOLOGI PENELITIAN

Langkah-langkah yang akan dilakukan dalam penelitian ini diantara lain ialah penyiapan lingkungan pengembangan, pengumpulan data, *preprocessing data*, membangun model dengan arsitektur *MobileNetV2*, dan evaluasi model. Langkah-langkah penelitian ini ditunjukkan pada Gambar 1.



Gambar 1. Alur Penelitian

2.1 Lingkungan Pengembangan

Penelitian ini memanfaatkan perangkat lunak (*software*) dan perangkat keras (*hardware*) yang ada, proses pelatihan dilakukan menggunakan beberapa perangkat keras secara langsung. Informasi lebih rinci mengenai spesifikasi, dapat dilihat pada Tabel 1.

Tabel 1. *Software dan Hardware*

Hardware	Software
CPU:AMD Athlon Silver 3050U 2.30 GHz	Python 3
Radeon Graphics 500 MB	Goggle Collab
Ram: 4GB	Google Drive
Harddisk: 1TB	Kaggle
SSD: 256GB	OS: Windows 11 TensorFlow

Berdasarkan Tabel 1, pemilihan perangkat keras dan perangkat lunak dalam penelitian ini sangat penting untuk efisiensi dan efektivitas pelatihan model klasifikasi citra *X-ray* dengan arsitektur *MobileNetV2*. Hardware terdiri dari CPU AMD Athlon Silver 3050U berkecepatan 2.30 GHz, yang cukup untuk mengolah perhitungan kompleks. Dilengkapi dengan Radeon Graphics 500 MB, sistem ini mendukung visualisasi data yang diperlukan. RAM 4 GB memungkinkan multitasking, sementara harddisk 1 TB menyediakan ruang penyimpanan untuk *dataset* besar dan model yang dilatih. SSD 256 GB memastikan akses data cepat, mempercepat loading dan pemrosesan pemilihan *dataset*. Perangkat lunak yang digunakan seperti bahasa pemrograman Python, Google Collab, Google Drive, Kaggle, Windows 11 dan TensorFlow. Bahasa pemrograman Python yang digunakan ialah versi 3, dimana bahasa tersebut sebagai bahasa pemrograman utama, didukung oleh pustaka seperti TensorFlow dan Keras untuk implementasi algoritma *deep learning* yang dilakukan. Google Colab berfungsi sebagai platform cloud dengan akses GPU gratis, mempercepat pelatihan model, sedangkan Google Drive memudahkan penyimpanan dan kolaborasi. Kaggle menyediakan sumber *dataset* yang relevan, dan Windows 11 digunakan sebagai sistem operasi, menawarkan antarmuka yang intuitif dan fitur keamanan. Kombinasi *hardware* dan *software* ini diharapkan dapat memberikan hasil akurat dan efisien dalam deteksi penyakit paru-paru, serta berkontribusi pada bidang kesehatan dan teknologi informasi.

2.2 Pengumpulan Data

Proses pengumpulan *dataset* yang akan digunakan bersumber dari salah satu sumber opensource yaitu Kaggle, salah satu platform di bidang ilmu data yang dapat melakukan akses keberbagai kumpulan data baik data skala kecil maupun bigdata dengan salah satunya yaitu terdapat data kesehatan [18]. Data Kesehatan tersebut salah satunya data gambar citra *X-Ray* yang akan digunakan pada penelitian ini. Pengumpulan *dataset* penelitian pada Kaggle melibatkan pencarian dengan berbagai kata kunci seperti, nama penyakit dan citra *X-Ray*. *Dataset* yang digunakan pada penelitian ini menggunakan lima kelas yaitu normal, pneumonia, pneumothorax, tuberculosis, dan kanker paru-paru. *Dataset* setiap kelas berjumlah 500 *dataset* gambar dengan total seluruhnya yaitu 2500 gambar citra.

2.3 Pre-processing Data

Pre-processing data atau pemrosesan data mencakup berbagai teknik dan prosedur yang digunakan untuk menyiapkan dan mengubah data mentah menjadi format yang sesuai untuk pelatihan Model *Deep Learning* [19]. Proses ini mencakup beberapa langkah yaitu *labelling data*, *transformation data*, dan *split data*. Langkah *labelling data*, kode berfokus pada pengumpulan dan penandaan gambar berdasarkan kelas yang sesuai, setiap subfolder dalam direktori *dataset* mewakili kategori tertentu, seperti “Normal”, “Pneumonia”, “Pneumothorax”, “Cancer”, dan “Tuberculosis”. Saat kode mengiterasi melalui setiap subfolder, memeriksa keberadaan gambar di dalamnya dan untuk setiap gambar yang ditemukan, kode membentuk path lengkapnya. Path tersebut kemudian disimpan dalam list filepaths, sementara label yang sesuai dengan kelas subfolder tersebut disimpan dalam list labels, dengan demikian, setiap gambar dihubungkan secara langsung dengan label yang mencerminkan kategorinya, menghasilkan data yang terstruktur dengan baik dan siap untuk digunakan dalam pelatihan model. Proses ini penting untuk memastikan bahwa model dapat belajar dari data yang telah dilabeli secara akurat dan konsisten.

Langkah *Pre-processing data* selanjutnya ialah *split data*, dimana model akan membagi *dataset* menjadi tiga yaitu *data training*, *data testing*, dan *data validation*. Masing-masing data akan dibagi menjadi 80% *data training*, 10% *data testing*, dan 10% *data validation*. Pembagian data ini dimaksudkan untuk menjaga integritas evaluasi dan menghindari bias yang mungkin terjadi jika data pengujian digunakan dalam pelatihan. Dengan pendekatan ini, diharapkan model yang dihasilkan dapat menunjukkan kemampuan klasifikasi yang kuat dan akurat dalam mendeteksi berbagai jenis penyakit paru-paru.

Langkah *transformation data*, fokus utama adalah normalisasi nilai *pixel* gambar untuk memastikan konsistensi dan efektivitas dalam pelatihan model. Dalam melakukan normalisasi tersebut pada *dataset* gambar dilakukan perubahan ukuran menjadi 224x224 *pixel* sesuai dengan standar pada input arsitektur *MobileNetV2* [20]. Citra berikutnya diubah ke format RGB dan dinormalisasi dengan membagi nilai setiap *pixel* dengan 255, sehingga setiap *pixel* memiliki nilai dalam rentang 0 hingga 1. Langkah ini bertujuan untuk mempercepat waktu komputasi [21]. Selain itu, penggunaan “*ImageDataGenerator*” memungkinkan berbagai augmentasi gambar seperti rotasi, perubahan cahaya, dan *zoom* [10]. Transformasi ini tidak hanya memperkaya variasi data yang tersedia untuk model, tetapi juga membantu dalam

meningkatkan generalisasi model terhadap data yang tidak terlihat sebelumnya. Normalisasi dan augmentasi *pixel* menjadi langkah untuk mempersiapkan data untuk analisis lebih lanjut dan pelatihan yang lebih efektif.

2.4 Training Model

Proses pelatihan model dalam penelitian ini menggunakan data yang telah disiapkan, dengan total 2000 gambar untuk data training. Model dilatih menggunakan arsitektur CNN yaitu MobileNetV2 [22] selama 40 *epoch*, dengan ukuran *batch* sebesar 64 dan 32 langkah (*steps*) per-*epoch*. Dalam penelitian ini, *optimizer* Adam dengan learning rate sebesar 0,001 digunakan untuk mengoptimalkan model. *Optimizer* ini berfungsi untuk meminimalkan nilai loss dan memaksimalkan akurasi model dengan mengintegrasikan fungsi loss dan parameter model untuk memperbarui model, sehingga membentuk model yang paling akurat [23]. Fungsi *loss* yang digunakan adalah *categorical crossentropy*, yang sesuai untuk masalah klasifikasi multi-kelas. Selama proses *training*, parameter model (bobot) diubah untuk meminimalkan fungsi *loss*, yang mengukur akurasi model dalam memprediksi data uji. Sebelum dilakukan pelatihan, data gambar juga diproses melalui tahap *pre-processing* dan augmentasi untuk meningkatkan kualitas dan variasi data. Proses yang ada dalam arsitektur MobileNetV2 dapat dilihat pada Tabel 2.

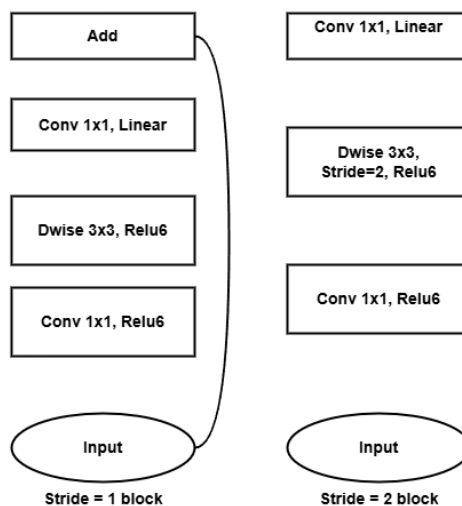
Tabel 2. Layer Training Model

Nama Layer	Output Shape
MobileNetV2	(None, 7, 7, 12800)
Convolution Layer	(None, 7, 7, 32)
Pooling Layer	(None, 7, 7, 32)
Dropout	(None, 7, 7, 32)
Flatten	(None, 288)
Dense	(None, 5)

a. MobilenetV2

MobileNetV2 merupakan salah satu arsitektur dari CNN yang dapat mengatasi kebutuhan *computing resource* berlebih, dimana *MobileNet* memiliki ukuran yang lebih kecil dan waktu komputasi lebih cepat pada proses pelatihan [17]. *MobileNet* juga di design sebagai “*mobile-fit*” oleh peneliti Google, hal tersebut dikarenakan *MobileNet* merupakan salah satu dari banyak arsitektur CNN dapat berjalan secara *mobile* [24].

MobileNetV2 adalah pengembangan dari *MobileNetV1* yang menawarkan peningkatan kinerja dengan tetap menjaga efisiensi. *MobileNetV2* memiliki struktur dasar seperti yang dimulai dengan konvolusi kedalaman yang ringan, di mana setiap saluran input difilter menggunakan satu filter konvolusi. Lapisan 1×1 (konvolusi titik) digunakan untuk menciptakan fitur baru melalui kombinasi linier dari saluran input. Aktivasi ReLU diterapkan pada *MobileNetV2* karena ketahanannya terhadap komputasi presisi rendah. *MobileNetV2* mengimplementasikan struktur residual, yang mencakup lapisan hambatan dalam koneksi residual, memungkinkan aliran informasi yang lebih baik. Arsitektur ini memiliki 32 *filter* pada lapisan konvolusi yang terhubung penuh diikuti oleh 19 lapisan hambatan residual. Lapisan ekspansi menengah memanfaatkan konvolusi kedalaman untuk menyaring fitur yang memberikan sumber penting dalam proses pembelajaran [25]. Arsitektur *MobileNetV2* dapat dilihat pada Gambar 2.



Gambar 2. Arsitektur *MobileNetV2*

b. Convolution layer

Lapisan konvolusi merupakan komponen penting dalam Metode CNN yang melibatkan proses konvolusi pada *output* dari lapisan sebelumnya. Lapisan ini memanfaatkan *filter* yang dikenal sebagai kernel untuk mengekstraksi fitur atau objek dari gambar masukan. Kernel tersebut berisi bobot yang berfungsi untuk mendeteksi karakteristik

objek. Proses selanjutnya konvolusi dilakukan untuk menghasilkan transformasi dari gambar masukan yang mencerminkan informasi dalam data tersebut [26].

c. *Pooling layer*

Lapisan *pooling* memiliki peran penting dalam menjaga dimensi data selama proses konvolusi dengan cara mengurangi jumlah sampel atau mengurangi dimensi spasial input. Melalui operasi *pooling* representasi data dapat disederhanakan, sehingga lebih mudah dikelola dan membantu dalam mengendalikan *overfitting*. Metode *pooling* yang paling sering digunakan adalah *Max Pooling* di mana nilai maksimum dari area tertentu dipilih. Metode lain yang dikenal sebagai *average pooling*, yang menghitung nilai rata-rata dari area yang sama [27].

d. *Dropout*

Dropout merupakan teknik yang diterapkan untuk mengurangi *overfitting* pada jaringan saraf dengan mencegah model dari adaptasi yang berlebihan selama pelatihan data. Metode ini juga dapat mempercepat proses pembelajaran dengan mengacak dan mengabaikan neuron yang tidak aktif selama fase pelatihan [26].

e. *Flatten*

Tahapan *flattening* merupakan proses mengubah matriks yang ada di lapisan *pooling* menjadi satu kolom atau vektor tunggal. Vektor ini akan menjadi bagian dari *input layer* dalam jaringan saraf tiruan. Peta fitur yang telah dipool sebelumnya, dengan cukup mengambil setiap baris dan menggabungkannya menjadi satu baris dengan satu kolom [27].

f. *Dense*

Dense layer atau bisa disebut dengan lapisan *fully connected* yang berfungsi untuk melakukan klasifikasi berdasarkan fitur yang diekstraksi dari lapisan sebelumnya. Proses klasifikasi Metode *Softmax* menghitung probabilitas untuk setiap kelas target relatif terhadap seluruh kelas yang ada. Nilai probabilitas yang dihasilkan oleh *Softmax* berkisar antara 0 dan 1. Jika semua probabilitas untuk kelas target dijumlahkan, totalnya akan sama dengan satu. *Softmax* mengambil nilai eksponensial dari *input* yang diberikan dan menjumlahkan nilai-nilai eksponensial tersebut untuk semua kelas dalam *output* [27].

2.5 Evaluasi

Evaluasi performa dilakukan terhadap model yang dihasilkan dari penggunaan arsitektur *MobileNetv2* saat melakukan pengujian dan pelatihan model. Performa model dinilai menggunakan metrik seperti presisi, akurasi, *recall*, dan *f1-score* [28]. Metrik-metrik ini dihitung berdasarkan *confusion matrix*, jika data positif diprediksi dengan benar disebut sebagai *true positive* (TP), jika diprediksi salah disebut *false negative* (FN), jika data negatif diprediksi dengan benar disebut *true negative* (TN), dan apabila prediksi salah disebut *false positive* (FP) [24].

a. *Accuracy*

Accuracy atau akurasi merupakan rasio prediksi yang dilakukan oleh model dengan nilai benar (positif+negative) terhadap keseluruhan data. Nilai akurasi dapat diperoleh dengan Persamaan (1).

$$Accuracy = \frac{\text{Jumlah klasifikasi benar}}{\text{Total Data}} \times 100\% \quad (1)$$

b. *Recall*

Recall merupakan nilai rasio yang didapatkan dari prediksi positif benar (TP) terhadap seluruh data yang bernilai positif benar (TP + FP). Nilai *recall* dapat diperoleh dari Persamaan (2).

$$Recall = \frac{TP}{TP + FP} \times 100\% \quad (2)$$

c. *Precision*

Precision atau presisi merupakan nilai rasio yang didapatkan dari adanya hasil benar positif (TP) terhadap keseluruhan nilai hasil prediksi positif (TP+FP) [29]. Nilai presisi ini dapat diperoleh dari Persamaan (3).

$$Precision = \frac{TP}{TP + FP} \times 100 \quad (3)$$

d. *F1-Score*

F1-Score merupakan kalkulasi evaluasi yang menggabungkan hasil dari perhitungan *precision* dan *recall*. *F1-Score* digunakan untuk mengatasi ketidakseimbangan kelas, seperti perbedaan jumlah data positif dan negatif [29]. *F1-Score* dapat diperoleh dari adanya Persamaan (4).

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \times 100\% \quad (4)$$

True Positive (TP) merupakan jumlah data dengan kelas positif yang berhasil diprediksi dengan benar oleh model, sedangkan *True Negative* (TN) adalah jumlah data dengan kelas negatif yang juga berhasil diprediksi secara tepat. *False Positive* (FP) menunjukkan jumlah data yang sebenarnya berkategori negatif namun salah diprediksi sebagai positif oleh model dan *False Negative* (FN) adalah jumlah data yang sebenarnya positif namun diprediksi sebagai negatif.

3. HASIL DAN PEMBAHASAN


3.1 Hasil Pengumpulan Data

Penelitian ini, menggunakan *dataset* gambar citra *X-Ray* atau Rotgen penyakit pada orang tubuh paru-paru yang memiliki lima kelas yaitu Normal, *Tuberculosis*, *Pneumonia*, *Pneumothorax*, dan *Cancer*, yang digunakan bersumber dari *website dataset open source* yaitu Kaggle. Tabel 3 menunjukkan hasil pengumpulan data yang digunakan dalam penelitian ini. Masing-masing kelas terdiri atas 500 gambar citra *X-Ray*, sehingga total keseluruhan data yang digunakan dalam penelitian ini berjumlah 2.500 citra. Pemilihan jumlah data yang seimbang pada setiap kelas bertujuan untuk menghindari masalah ketidakseimbangan kelas (*class imbalance*) yang dapat memengaruhi performa model klasifikasi. Penggunaan data yang merata ini memungkinkan pelatihan model yang lebih adil dan mendorong kemampuan pembacaan gambar yang lebih baik terlebih dalam kasus klasifikasi multi-kelas.

Tabel 1. Hasil Pengumpulan Data

No	Kelas	Jumlah Data
1	Cancer	500
2	Normal	500
3	Pneumonia	500
4	Pneumothorax	500
5	Tuberculosis	500
	Total	2.500

Keberagaman dalam gambar *X-Ray* yang digunakan juga dipertimbangkan, mencakup variasi dalam pencahayaan, sudut pengambilan gambar, dan kondisi kesehatan pasien. Hal ini bertujuan untuk menciptakan model yang lebih robust dan dapat diandalkan dalam situasi dunia nyata. Secara keseluruhan, pemilihan dan pengumpulan data ini diharapkan dapat menghasilkan model klasifikasi yang akurat dan efektif dalam mendeteksi berbagai jenis penyakit paru-paru.



Gambar 3. Visualisasi Dataset

Visualisasi ini bertujuan untuk memberikan gambaran awal mengenai variasi karakteristik radiologis antar kelas, serta untuk memperkuat pemahaman terkait klasifikasi citra medis berbasis *X-Ray* seperti yang ditunjukkan Gambar 3. Gambar 3 (a) menunjukkan kondisi paru-paru normal yang tidak memiliki indikasi kelainan radiologis. Gambar 3 (b) merupakan contoh kasus kanker paru-paru, yang umumnya ditandai dengan adanya massa atau lesi abnormal pada area paru. Gambar 3 (c) menunjukkan pasien dengan pneumonia, yang biasanya memperlihatkan area infiltrasi atau opasitas pada parenkim paru. Sementara itu, Gambar 3 (d) menggambarkan kondisi pneumothorax, yaitu penumpukan udara dalam rongga dada yang menyebabkan kolaps sebagian atau seluruh paru. Terakhir, Gambar 3 (e) memperlihatkan gambaran tuberkulosis, yang dapat ditandai dengan adanya kalsifikasi, kavitas, atau perubahan struktural lain pada paru-paru.

3.2 Pre-processing Data

3.2.1 Hasil Proses Pembagian Data

Dataset yang digunakan dibagi menjadi tiga yaitu: Data pelatihan yang mencakup 80% dari total *dataset*, digunakan untuk mengajarkan model mengenali pola dan fitur dari setiap kelas penyakit. Sementara itu, data validasi berfungsi sebagai set yang terpisah untuk mengoptimalkan *hyperparameter* model dan memantau kemungkinan terjadinya *overfitting*. Ini penting untuk memastikan bahwa model tidak hanya belajar dari data pelatihan tetapi juga dapat generalisasi dengan baik pada data yang belum pernah dilihat sebelumnya. Data pengujian, yang terdiri dari 10% dari *dataset*, digunakan untuk evaluasi akhir performa model setelah pelatihan dan validasi. Data ini memberikan gambaran yang jelas tentang seberapa baik model dapat memprediksi kelas penyakit pada data baru.

Penelitian ini membagi data yang ada menjadi 2000 data pelatihan, 250 data validasi, dan 250 data pengujian, seperti ditunjukkan pada Tabel 4.

Tabel 2. Pembagian Dataset

Data Pelatihan	Data Validasi	Data Pengujian
80%	10%	10%

Data Pelatihan	Data Validasi	Data Pengujian
2000	250	250

3.2.2 Hasil Augmentasi Data

Proses *augmentasi* data dan persiapan *dataset* untuk pelatihan model dalam pengenalan citra dilakukan dengan mempertimbangkan berbagai parameter penting. Ukuran gambar ditetapkan pada 224x224 *pixel* dengan 3 saluran warna, dan ukuran batch pelatihan ditentukan sebesar 64. Proses selanjutnya dengan melakukan normalisasi, di mana nilai *pixel* gambar diubah menjadi rentang [0, 1] melalui proses *rescale* dengan membagi nilai *pixel* yang awalnya berada dalam rentang [0, 255]. Proses normalisasi dilakukan untuk mempercepat proses pelatihan dan meningkatkan akurasi prediksi. Selain itu, generator terpisah disiapkan untuk validasi dan pengujian dengan menggunakan normalisasi tetapi tanpa pengacakan pada data uji agar evaluasi tetap konsisten. Kelas-kelas dalam *dataset* pelatihan diidentifikasi dan jumlahnya dihitung untuk keperluan pelatihan model. *Dataset* disiapkan secara optimal untuk memastikan model dapat belajar secara efektif dan meminimalkan potensi bias akibat ketidakseimbangan data antar kelas.



(a) Gambar asli



(b) Gambar hasil augmentasi

Gambar 4. Contoh Augmentasi

Gambar 4 menunjukkan dua citra rontgen dada yang digunakan dalam penelitian ini, yaitu gambar asli dan gambar hasil augmentasi. Gambar 4 (a) merupakan gambar rontgen dada yang diambil tanpa modifikasi. Gambar ini memberikan representasi dasar dari struktur paru-paru dan area sekitarnya. Analisis terhadap gambar ini penting untuk identifikasi penyakit-penyakit paru-paru seperti pneumonia, pneumothorax, dan tuberculosis. Namun, gambar asli mungkin tidak selalu jelas atau memiliki kontras yang cukup untuk mendeteksi kelainan dengan akurasi tinggi.

Gambar 4 (b) citra ini merupakan hasil dari proses augmentasi, di mana teknik seperti peningkatan kontras, rotasi, dan penghilangan noise diterapkan pada gambar tersebut. Augmentasi bertujuan untuk memperkaya variasi data dan meningkatkan kemampuan model dalam mengenali pola yang mungkin tidak terlihat pada gambar asli. Proses ini membantu dalam memperbaiki kualitas visual gambar, sehingga model dapat belajar dari data yang lebih beragam dan memperbaiki akurasi deteksi.

Proses augmentasi gambar yang telah dilakukan bertujuan untuk memperkaya *dataset* dan meningkatkan kemampuan model dalam mengenali berbagai variasi citra. Augmentasi ini penting untuk memperluas keragaman data pelatihan tanpa perlu mengumpulkan lebih banyak gambar. Dengan menerapkan teknik augmentasi model dapat belajar dari citra yang telah diperbaiki. Dengan augmentasi akan memberikan variasi di dalam data, sehingga augmentasi membantu model untuk tidak hanya mengandalkan fitur-fitur spesifik dari citra pelatihan, tetapi juga untuk belajar mengenali pola yang lebih umum. Hal ini sangat penting dalam konteks klasifikasi penyakit paru-paru, di mana gambar rontgen dapat bervariasi secara signifikan karena faktor-faktor seperti sudut pengambilan gambar dan kondisi kesehatan pasien.

Hasil dari augmentasi gambar diharapkan dapat berkontribusi pada peningkatan akurasi model dalam klasifikasi. Dengan *dataset* yang lebih beragam model diharapkan dapat mengatasi tantangan yang muncul dari ketidakpastian dalam melakukan pembacaan secara manual dan memberikan hasil yang lebih andal dalam diagnosis penyakit paru-paru secara otomatis dengan teknologi yang akan dikembangkan.

3.3 Pengujian Model

Tahap pengujian dalam penelitian ini bertujuan untuk mengevaluasi performa arsitektur MobileNetV2 dalam mengklasifikasikan lima kelas kondisi paru-paru, yaitu pneumonia, pneumotoraks, tuberculosis, kanker paru-paru, dan kondisi normal. MobileNetV2 dipilih karena memiliki arsitektur ringan dan efisien secara komputasi, sehingga cocok untuk pengembangan sistem pendeteksi penyakit berbasis perangkat bergerak atau website yang memiliki keterbatasan sumber daya. Pengujian dilakukan melalui beberapa tahapan evaluasi, termasuk analisis visual terhadap grafik training dan validation loss atau akurasi, serta evaluasi numerik menggunakan confusion matrix untuk memperoleh metrik performa model secara kuantitatif. Analisis grafik bertujuan untuk memahami dinamika proses pembelajaran model selama 40 *epoch*, seperti kestabilan konvergensi dan kecenderungan terhadap overfitting.

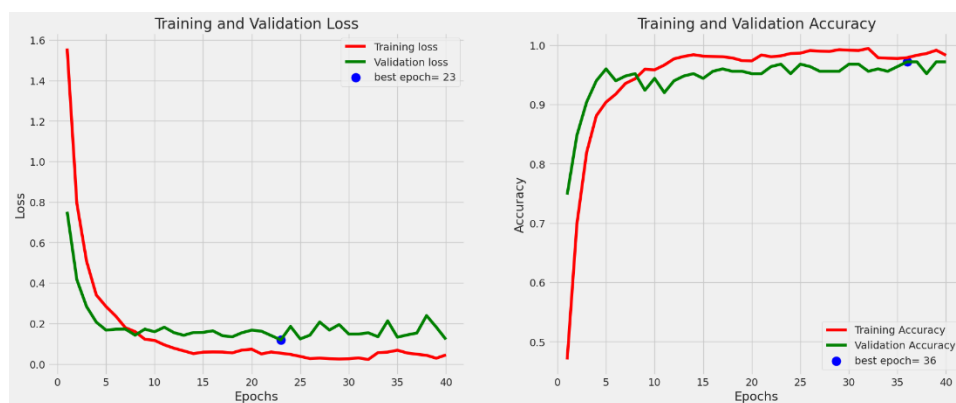
Proses evaluasi klasifikasi dilakukan dengan menggunakan confusion matrix, yang memberikan gambaran jumlah prediksi benar dan salah untuk masing-masing kelas. Dari matriks ini, dihitung nilai evaluatif seperti akurasi, *precision*, *recall*, dan *F1-score* pada masing-masing kelas, guna menilai keseimbangan performa klasifikasi antar kelas. Proses pelatihan model dilakukan menggunakan *optimizer* Adam dengan learning rate sebesar 0.001 dan batch

size 64. Fungsi loss yang digunakan adalah categorical crossentropy, sementara metrik utama untuk pemantauan selama pelatihan adalah akurasi. Seluruh proses pelatihan dan pengujian dijalankan menggunakan library Keras dengan backend TensorFlow, dan model dilatih selama 40 epoch, memungkinkan MobileNetV2 mempelajari pola visual khas dari masing-masing kelas penyakit paru-paru dalam citra *X-Ray*. Pengujian ini tidak hanya mengukur kemampuan model dalam mengenali pola citra, tetapi juga mengevaluasi kemampuannya untuk melakukan generalisasi terhadap data baru yang belum pernah dilihat sebelumnya.

3.4 Hasil Akurasi Model

Berdasarkan Gambar 5, grafik menunjukkan kinerja Model CNN dengan Arsitektur *MobileNetV2* selama 40 epoch. Dari grafik, terlihat bahwa akurasi pelatihan meningkat secara konsisten, sementara akurasi validasi juga meningkat, meskipun dengan laju yang lebih lambat. Setelah sekitar 10 epoch, akurasi validasi mulai stabil, yang menunjukkan bahwa model sudah mulai bisa memahami pola dari data. Pada epoch ke-36, model mencapai akurasi tertinggi pada data validasi, hampir mendekati 1, yang menandakan performa yang sangat baik.

Grafik juga menunjukkan *training loss* menurun dengan cepat pada awal pelatihan dan kemudian stabil pada nilai rendah, namun *validation loss* menunjukkan peningkatan di beberapa epoch, yang bisa menjadi tanda bahwa model mulai terlalu fokus pada data pelatihan dan kurang efektif pada data baru atau dikenal sebagai *overfitting*. Oleh karena itu, penting untuk memantau kinerja model sehingga langkah-langkah dapat diambil untuk menghindari *overfitting*, seperti menyesuaikan parameter model. Dengan cara ini, model dapat beradaptasi dengan baik pada data yang belum pernah dilihat sebelumnya, sehingga meningkatkan akurasi dalam prediksi di dunia nyata.



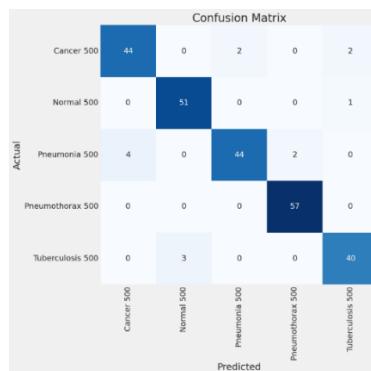
Gambar 5. Grafik Pengujian Model

Keterbatasan dari penelitian ini, dimana *dataset* yang digunakan masih terbatas dari segi jumlah dan variasi sumber seperti belum mencakup data dari berbagai rumah sakit atau perangkat *X-Ray* yang berbeda, tidak adanya validasi klinis oleh tenaga medis profesional, dan belum dilakukan pengujian langsung pada data eksternal. Keterbatasan tersebut menjadikan hasil model penelitian sebelum sistem ini diterapkan secara luas diperlukan tahapan validasi lebih lanjut dengan institusi medis secara langsung untuk dilakukannya uji coba.

Secara keseluruhan, hasil penelitian ini menunjukkan bahwa MobileNetV2 dapat menjadi solusi efektif untuk klasifikasi multi-kelas penyakit paru-paru berbasis citra *X-Ray*. Performa model yang tinggi dan efisiensi komputasi menjadikan model ini memiliki potensi besar untuk dikembangkan lebih lanjut dalam bentuk aplikasi medis digital yang dapat meningkatkan akses deteksi dini penyakit paru-paru secara cepat dan terjangkau di berbagai wilayah, khususnya daerah dengan keterbatasan infrastruktur medis.

3.5 Evaluasi Model

Hasil dari *confusion matrix* dari arsitektur CNN yaitu MobileNetV2 dari pengujian yang telah dilakukan menggunakan *batch size* 64 dan *epoch* 40, dengan akurasi training mencapai 98,76% dan validasi training mencapai 97,20%. Gambar 6 menunjukkan hasil dari pengujian menggunakan *confusion matrix* yang berhasil melakukan klasifikasi ataupun deteksi penyakit pada paru-paru dengan arsitektur *MobileNetV2*. Model yang telah dihasilkan berhasil melakukan prediksi dengan tepat 236 dari data total 250 data uji. Berdasarkan *confusion matrix* model menunjukkan akurasi sangat tinggi dalam mengklasifikasikan Pneumothorax, dengan *True Positive* (TP) sebesar 57 dan *False Negative* (FN) nol, menandakan seluruh citra Pneumothorax dikenali dengan benar. Kelas lain seperti Cancer, Pneumonia, dan Tuberculosis masih terdapat kekeliruan klasifikasi silang, seperti kasus Pneumonia yang salah diklasifikasikan sebagai Cancer dan sebaliknya. Kelas Normal juga memiliki performa cukup baik dengan TP sebesar 51 dengan satu kasus salah klasifikasi. Keseluruhan hasil ini menunjukkan bahwa model memiliki kinerja yang kuat pada beberapa kelas, hasil tersebut membuktikan bahwa model dapat berfungsi dengan baik.



Gambar 6. Confussion Matrix

Tabel 3. Hasil Evaluasi Model

Kelas	Precision	Recal	F1-score
Normal	0.94	0.98	0.96
Cancer	0.92	0.92	0.92
Pneumonia	0.96	0.88	0.92
Pneumothorax	0.97	1.00	0.98
Tuberculosis	0.93	0.93	0.93

Tabel 5 menampilkan nilai *matrix* evaluasi seperti *precision*, *recall*, dan *f1-score* untuk setiap kategori penyakit paru-paru untuk memberikan gambaran dari performa model dalam melakukan klasifikasi pada setiap kelas. Setiap kelas menggunakan 43 hingga 57 data sampel untuk melakukan pengujian model. Hasil pengujian model menunjukkan performa yang sangat baik secara keseluruhan, dengan akurasi sebesar 94%. Nilai *precision*, *recall*, dan *f1-score* untuk tiap kelas berada dalam rentang 0.88 hingga 1.00, hasil tersebut memberikan gambaran bahwa keseimbangan yang cukup baik antara kemampuan model dalam mendeteksi positif yang benar (*recall*) dan ketepatan prediksi positifnya (*precision*). Nilai *f1-score* tertinggi diperoleh pada kelas Pneumothorax dengan nilai mencapai 0.98, memberikan gambaran bahwa model sangat efektif dalam mengklasifikasikan setiap kelasnya. Model yang dibuat memiliki rata-rata makro dan tertimbang (*macro avg* dan *weighted avg*) juga menunjukkan nilai yang tinggi dan konsisten dengan nilai mencapai 0.94, hasil tersebut menandakan bahwa performa model merata di seluruh kelas tidak hanya pada satu kelas tertentu.

Hasil evaluasi dari pelatihan model dengan Arsitektur *MobileNetV2* menunjukkan kinerja klasifikasi yang sangat memuaskan, dengan akurasi keseluruhan mencapai 94%. Pencapaian ini signifikan mengingat model diuji pada lima kelas penyakit paru-paru pneumonia, pneumothoraks, tuberkulosis, kanker paru-paru, dan normal yang memiliki kompleksitas lebih tinggi dibandingkan dengan penelitian sebelumnya yang hanya melibatkan dua hingga empat kelas. Sebagai contoh, penelitian [13] hanya menggunakan 98 citra dan menghasilkan akurasi 87,88%, sementara penelitian [14] mencapai akurasi 91% dengan empat kelas. Meskipun hasil penelitian ini sedikit lebih rendah dibandingkan dengan akurasi tertinggi 98,69% dari penelitian [15] yang hanya mengklasifikasikan dua kelas (normal dan tuberkulosis), model ini tetap menunjukkan performa yang kompetitif dalam konteks multi-kelas yang lebih kompleks. Nilai *F1-score* yang tinggi, khususnya pada kelas pneumothoraks (0.98), menunjukkan efektivitas model dalam mengenali fitur-fitur citra *X-Ray* di seluruh kategori penyakit, tidak hanya pada kelas dominan.

Hasil model penelitian ini mencerminkan kontribusi signifikan terhadap tujuan penelitian, yaitu membangun model klasifikasi multi-kelas yang ringan dan efisien untuk sistem deteksi otomatis penyakit paru-paru berbasis teknologi. Meskipun grafik *loss* pelatihan dan validasi menunjukkan tren stabil tanpa indikasi *overfitting* yang berarti, potensi *overfitting* tetap menjadi perhatian yang harus diperhatikan melalui pemantauan akurasi validasi dan penerapan teknik augmentasi data. Tantangan lain, seperti ketidakseimbangan jumlah sampel antar kelas, diatasi dengan pemilihan *batch size* yang lebih besar dan pelatihan selama 40 *epoch*, memungkinkan model untuk belajar secara menyeluruh. Namun, keterbatasan tetap ada pada ukuran dataset yang terbatas, yang belum mencakup variasi citra klinis secara global. Implikasi dari hasil ini menunjukkan bahwa meskipun menggunakan arsitektur *MobileNetV2* yang ringan, model ini dapat menghasilkan kinerja tinggi dalam klasifikasi penyakit paru yang kompleks. Hasil tersebut menjadikannya model bisa dikembangkan sebagai alat dalam sistem skrining awal bagi tenaga medis dalam melakukan pembacaan citra yang bisa mendeteksi penyakit dalam paru-paru.

4. KESIMPULAN

Berdasarkan hasil dan pembahasan yang telah dijelaskan, penelitian ini berhasil mengklasifikasikan penyakit paru-paru menggunakan metode CNN dengan Arsitektur *MobileNetV2*. *Dataset* yang digunakan terdiri dari 2500 gambar citra *X-Ray* yang terbagi menjadi lima kelas penyakit, dengan pembagian 2000 data untuk pelatihan, 250 data untuk pengujian, dan 250 data untuk validasi. Proses preprocessing meliputi *resizing* gambar menjadi 224x224 *pixel* dan

normalisasi nilai *pixel* ke dalam rentang 0 hingga 1, teknik augmentasi diterapkan untuk memperkaya variasi data. Model yang dihasilkan menunjukkan performa yang baik, dengan akurasi pelatihan mencapai 98,76% dan akurasi validasi sebesar 97,20%. Evaluasi model menggunakan *confusion matrix* menghasilkan nilai *f1-score* keseluruhan sebesar 0,94 dengan nilai *f1-score* tertinggi yaitu 0,98 pada kelas pneumothorax. Hasil ini menunjukkan bahwa model mampu mendeteksi dan mengklasifikasikan penyakit paru-paru secara akurat dengan akurasi sebesar 94,40%. Penelitian ini memberikan kontribusi signifikan dalam pengembangan sistem deteksi otomatis penyakit paru-paru yang dapat diimplementasikan dalam aplikasi berbasis *website* atau *mobile*, menunjukkan performa yang baik dan seimbang di setiap kelas.

REFERENCES

- [1] F. Hasan, E. B. Priambudi, D. A. Putra, and A. P. Sari, "Analisis Citra Chest X-Rays Untuk Diagnosis Penyakit Pneumothorax Menggunakan Metode Box-Counting," *Pros. Semin. Nas. Inform. Bela Negara*, vol. 4, pp. 99–103, 2024, doi: 10.33005/santika.v4i.
- [2] M. Hussein, A. E. Minarno, and Y. Azhar, "Segmentasi Citra X-ray Paru dengan Deep Learning," *Repositor*, vol. 5, no. 1, pp. 581–590, 2023, doi: 10.22219/repositor.v5i1.32034.
- [3] Kementerian Kesehatan Republik Indonesia, "Profil Kesehatan Indonesia Tahun 2023," Jakarta, 2024. [Online]. Available: <https://kemkes.go.id/id/profil-kesehatan-indonesia-2023>
- [4] I. S. Utara, T. Pustaka, S. Sutrisno, and H. Sciences, "Analisis Teknologi Usia Tulang Menggunakan Kecerdasan Artifisial: Studi Bibliometrik," *Ibnu Sina J. Kedokt. Dan Kesehat. - Fak. Kedokt. Univ. Islam Sumatera Utara*, vol. 24, no. 1, pp. 147–158, 2025, doi: 10.30743/ibnusina.v24i1.759.
- [5] J. L. Phandany, A. M. Sambul, and A. S. M. Lumenta, "Comparative Study of Digital Image Optimal Compression Algorithm Using Python," *J. Tek. Elektro dan Komput.*, vol. 11, no. 1, pp. 23–34, 2022, doi: 10.35793/jtek.11.1.2022.37209.
- [6] I. Bakti, M. Firdaus, and S. Artikel, "Arsitektur Convolutional Neural Network InceptionResNet-V2 Untuk Pengelompokan Pneumonia Chest X-Ray," *J. Komput. Dan Teknol.*, vol. 2, no. 1, pp. 35–42, 2023, doi: 10.58290/jukomtek.v1i2.66.
- [7] R. Soekarta, M. Yusuf, and N. A. Basri, "Implementasi Deep Learning Untuk Deteksi Jenis Obat Menggunakan Algoritma CNN Berbasis Website," *J. Inform.*, vol. 7, no. 4, pp. 455–464, 2023, doi: 10.31000/jika.v7i4.9751.
- [8] H. R. Qalbi, E. M. Yuniarmo, and R. F. Rachmadi, "Klasifikasi Gerakan Cuci Tangan Berbasis Convolutional Neural Network (CNN)," *J. Tek. ITS*, vol. 10, no. 2, 2021, doi: 10.12962/j23373539.v10i2.75377.
- [9] R. M. Diar, R. Y. N. Fu'adah, and K. Usman, "Klasifikasi Penyakit Paru-Paru Berbasis Pengolahan Citra X Ray Menggunakan Convolutional Neural Network," *e-Proceeding Eng.*, vol. 9, no. 2, pp. 476–484, 2022.
- [10] R. Indraswari, W. Herulambang, and R. Rokhana, "Deteksi Penyakit Mata Pada Citra Fundus Menggunakan Convolutional Neural Network (CNN)," *Techno.Com*, vol. 21, no. 2, pp. 378–389, 2022, doi: 10.33633/tc.v21i2.6162.
- [11] P. S. Fransisca and N. Matondang, "Deteksi Citra Digital Penyakit Cacar Monyet menggunakan Algoritma Convolutional Neural Network dengan Arsitektur MobileNetV2," *J. Ilmu Komput. dan Agri-Informatika*, vol. 10, no. 2, pp. 200–211, 2023, doi: 10.29244/jika.10.2.200-211.
- [12] S. Andika Maulana, S. Husna Batubara, Y. Permata Putri Pasaribu, H. Syahputra, and F. Ramadhani, "Deteksi Burung Menggunakan Convolutional Neural Network (Cnn) Dengan Model Arsitektur Mobilenetv2," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 8, no. 4, pp. 6108–6114, 2024, doi: 10.36040/jati.v8i4.10126.
- [13] I. Bakti and M. Firdaus, "Klasifikasi File Gambar Hasil X-Ray Paru-Paru Dengan Arsitektur Convolution Neural Network (CNN)," *Jifotech (Journal Inf. Technol.*, vol. 3, no. 1, pp. 26–34, 2023, doi: 10.46229/jifotech.v3i1.590.
- [14] M. A. Alghozali *et al.*, "Klasifikasi Penyakit Pneumonia Citra Digital X-Ray Menggunakan Metode Convolutional Neural Network dan RGB Equalization," *Pros. Semin. Nas. Teknol. Dan Sains*, vol. 3, pp. 229–236, 2024, doi: 10.29407/stains.v3i1.4290.
- [15] H. A. Mubarak and R. Novita, "Klasifikasi Citra X-Ray Tuberkulosis Menggunakan Convolutional Neural Networks," *Build. Informatics, Technol. Sci.*, vol. 6, no. 4, pp. 2204–2216, 2025, doi: 10.47065/bits.v6i4.6515.
- [16] H. Istiqomah, P. Purwono, and R. Ardianto, "Prediksi Kanker Darah Menggunakan Metode Convolutional Neural Network," *J. Ilmu Komput. dan Inform.*, vol. 4, no. 1, pp. 51–60, 2024, doi: 10.54082/jiki.156.
- [17] A. Mahadar, P. Mangukiya, and T. Baraskar, "Comparison and Evaluation of CNN Architectures for Classification of Covid-19 and Pneumonia," *Proc. IEEE Int. Conf. Image Inf. Process.*, vol. 2021-Novem, pp. 110–115, 2021, doi: 10.1109/ICIIP53038.2021.9702676.
- [18] F. N. Darmawan, E. P. Silmina, and T. Hardiani, "Sistem Klasifikasi Penyakit Kulit Menggunakan Metode Convolutional Neural Network (CNN) Berbasis Website," *Pros. Semin. Nas. Penelit. Dan Pengabd. Kpd. Masy. LPPM Univ. 'Aisyiyah Yogyakarta*, vol. 2, no. September, pp. 871–881, 2024, doi: 10.54066/jptis.v2i2.1931.
- [19] N. T. Adam, Z. A. Tyas, and T. Hardiani, "Deteksi Gestur Sistem Isyarat Bahasa Indonesia Menggunakan Metode Deep learning SSD MobileNet V2 FPNLite," *Sainteks*, vol. 21, no. 2, pp. 129–142, 2024, doi: 10.30595/sainteks.v21i2.24006.
- [20] A. ANHAR and R. A. PUTRA, "Perancangan dan Implementasi Self-Checkout System pada Toko Ritel menggunakan Convolutional Neural Network (CNN)," *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron.*, vol. 11, no. 2, p. 466, 2023, doi: 10.26760/elkomika.v11i2.466.
- [21] A. Akram, K. Fayakun, and H. Ramza, "Klasifikasi Hama Serangga pada Pertanian Menggunakan Metode Convolutional Neural Network," *Build. Informatics, Technol. Sci.*, vol. 5, no. 2, pp. 397–406, 2023, doi: 10.47065/bits.v5i2.4063.
- [22] A. H. Nasrullah and H. Annur, "Implementasi Metode Convolutional Neural Network Untuk Identifikasi Citra Digital Daun," *J. Media Inform. Budidarma*, vol. 7, no. 2, p. 726, 2023, doi: 10.30865/mib.v7i2.5962.
- [23] F. Ramadhan; and J. Hernadi, "Evaluasi Optimizer Adam dan RMSProp Pada Arsitektur VGG-19 Klasifikasi Ekspresi Wajah Manusia," *JIPi (Jurnal Ilm. Penelit. dan Pembelajaran Inform.*, vol. 10, no. 2, pp. 1414–1426, 2025, doi: 10.29100/jipi.v10i2.6197.
- [24] O. V. Putra, M. Z. Mustaqim, and D. Muriatmoko, "Transfer Learning untuk Klasifikasi Penyakit dan Hama Padi Menggunakan MobileNetV2," *Techno.Com*, vol. 22, no. 3, pp. 562–575, 2023, doi: 10.33633/tc.v22i3.8516.



- [25] J. Praveen Gujjar, H. R. Prasanna Kumar, and N. N. Chiplunkar, "Image classification and prediction using transfer learning in colab notebook," *Glob. Transitions Proc.*, vol. 2, no. 2, pp. 382–385, 2021, doi: 10.1016/j.gltp.2021.08.068.
- [26] R. Magdalena, S. Saidah, N. K. C. Pratiwi, and A. T. Putra, "Klasifikasi Tutupan Lahan Melalui Citra Satelit SPOT-6 dengan Metode Convolutional Neural Network (CNN)," *J. Edukasi dan Penelit. Inform.*, vol. 7, no. 3, p. 335, 2021, doi: 10.26418/jp.v7i3.48195.
- [27] D. Husen, K. Kusriani, and K. Kusnawi, "Deteksi Hama Pada Daun Apel Menggunakan Algoritma Convolutional Neural Network," *J. Media Inform. Budidarma*, vol. 6, no. 4, p. 2103, 2022, doi: 10.30865/mib.v6i4.4667.
- [28] K. Shankar, Y. Zhang, Y. Liu, L. Wu, and C. H. Chen, "Hyperparameter Tuning Deep Learning for Diabetic Retinopathy Fundus Image Classification," *IEEE Access*, vol. 8, pp. 118164–118173, 2020, doi: 10.1109/ACCESS.2020.3005152.
- [29] R. AGUSTINA, R. MAGDALENA, and N. K. C. PRATIWI, "Klasifikasi Kanker Kulit menggunakan Metode Convolutional Neural Network dengan Arsitektur VGG-16," *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron.*, vol. 10, no. 2, p. 446, 2022, doi: 10.26760/elkomika.v10i2.446.