

Identifikasi Pneumonia pada Balita melalui Citra X-ray Menggunakan Metode *Convolutional Neural Network* (CNN)

Indah Kurniawati¹, Ridho Akbar^{2*}, Izza Fahma Kusumawati³, Yessie Ardina Kusuma⁴

Department of Electrical Engineering, Universitas Muhammadiyah Surabaya^{1,4}

Department of Industrial Engineering, Universitas Muhammadiyah Surabaya^{2,3}

Institute of Information Processing and Automation, Zhejiang University of Technology²

indah.kurniawati@ft.um-surabaya.ac.id¹ ridho.akbar@um-surabaya.ac.id² yessie.ardina@um-surabaya.ac.id³

izzafkusumawati@gmail.com⁴

Informasi Artikel

Riwayat Artikel:

Disubmit Juli 7, 2024

Diterima Juli 15, 2024

Diterbitkan Juli 23, 2024

Kata Kunci:

Pneumonia

Convolutional Neural Network (CNN)

Diagnosis

Rontgen X-ray Paru

ABSTRAK

Latar Belakang: Pneumonia adalah penyakit infeksi pada saluran pernapasan yang dapat menyebabkan hilangnya nyawa jika tidak didiagnosis dan diobati dengan tepat. Diagnosis pneumonia saat ini masih bergantung pada kemampuan dokter spesialis paru untuk mengevaluasi hasil rontgen dada (X-ray). Oleh karena itu, dibutuhkan teknologi yang dapat membantu dokter untuk menganalisis foto rontgen dengan cepat dan akurat. **Metode:** Penelitian menggunakan *Convolutional Neural Network* (CNN) untuk mengklasifikasikan foto rontgen paru ke dalam tiga kelas: Normal, Pneumonia Ringan, dan Pneumonia Berat. Beberapa eksperimen dilakukan dengan memvariasikan jumlah epoch, ukuran dataset, resolusi gambar, dan jumlah hidden layer untuk mendapatkan hasil yang akurat dari setiap identifikasi. **Hasil:** Hasil pengujian akhir menunjukkan bahwa menggunakan 15 epoch, 5 hidden layer, dan 5700 data dari proses klasifikasi menggunakan CNN dapat mencapai akurasi training sebesar 92,48% dan validasi sebesar 91%. Hasil dari 50 data foto rontgen dada menunjukkan akurasi identifikasi yang sama antara pembacaan oleh dokter dan metode yang diusulkan, dengan waktu pembacaan dokter 15 menit dan metode yang diusulkan hanya 0,2 detik dengan akurasi identifikasi 100%. **Kesimpulan:** Penelitian ini menunjukkan bahwa penggunaan metode yang diusulkan dapat membantu dokter spesialis paru untuk mendiagnosis pneumonia dengan akurasi diagnosis tinggi dan waktu diagnosis singkat, sehingga dapat membantu meningkatkan kualitas pelayanan kesehatan.

© This work is licensed under a Creative Commons Attribution 4.0 International License.

*Penulis Korespondensi:

Ridho Akbar

Departement of Industrial Engineering

Universitas Muhammadiyah Surabaya

Jl. Sutorejo 59, Surabaya, Indonesia

Email: ridho.akbar@um-surabaya.ac.id

1. PENDAHULUAN

Penggunaan sistem kecerdasan buatan semakin berkembang, terutama dalam mendukung pengambilan keputusan klinis seperti anamnesis, diagnosis, terapi, dan prognosis. Walaupun sistem-sistem ini hanya berperan sebagai alat bantu bagi para klinisi, kehadirannya sangat diperlukan [1].

Di bidang medis, telah terjadi pergeseran dari analisis penyakit secara manual menjadi analisis yang menggunakan alat atau sistem pakar yang lebih efisien dan hemat tenaga.

Pneumonia merupakan penyebab utama kematian anak di bawah usia lima tahun di dunia, melebihi penyakit lain seperti AIDS, malaria, dan campak. Namun, perhatian terhadap penyakit ini masih kurang. Di dunia, dari 9 juta kematian balita, lebih dari 2 juta anak meninggal setiap tahun akibat pneumonia, atau setara dengan 4 anak setiap menitnya [2]. Angka morbiditas pneumonia pada bayi adalah 2,2% dan pada balita 3%, sementara angka mortalitas pada bayi mencapai 23,8% dan pada balita 15,5% [3]. Pneumonia menjadi salah satu penyebab kematian tertinggi pada anak-anak di dunia, dengan WHO memperkirakan penyakit ini menyebabkan 15% dari seluruh kematian anak di bawah usia lima tahun. Pada tahun 2015, lebih dari 900.000 anak meninggal akibat *pneumonia*, dan di Indonesia sendiri, pneumonia diperkirakan telah merenggut sekitar 25.000 nyawa balita pada tahun 2013. Pneumonia dapat menjadi infeksi paru-paru biasa atau kadang kala mematikan, dan dapat disebabkan oleh infeksi dikarenakan bakteri atau virus [4]

Saat ini, banyak komplikasi medis (misalnya, deteksi tumor otak, deteksi kanker payudara, dll.) menggunakan solusi berbasis Kecerdasan Buatan [5]. Di antara teknik pembelajaran mendalam, convolutional neural networks (CNN) telah menunjukkan potensi besar dalam klasifikasi gambar dan oleh karena itu secara luas diteliti oleh peneliti [6]. Teknik deep learning pada X-ray paru-paru semakin populer karena mudah digunakan dengan teknik pengolahan citra berbiaya rendah dan tersedia banyak data untuk melatih berbagai model pembelajaran. Penelitian [7], [8] telah melaporkan penggunaan algoritma deep learning dalam deteksi pneumonia dan satu artikel [9] yang melaporkan klasifikasi pneumonia bakteri dan virus.

Dalam prosedur diagnosis pneumonia, X-ray dianggap sebagai metode yang efektif untuk menentukan sejauh mana dan lokasi area infeksi di paru-paru. Namun, pemeriksaan radiografi dada bukanlah tugas yang mudah bagi radiolog. Pada gambar X-ray paru, penampakan pneumonia bisa samar dan dapat disalahartikan dengan diagnosis lain. Evaluasi X-ray khususnya dalam kasus pneumonia dapat menyesatkan karena banyak juga dipengaruhi masalah lain seperti gagal jantung kongestif, jaringan parut paru-paru, dan lain-lain dapat menyerupai pneumonia. Inilah alasan utama di balik kesalahan klasifikasi citra X-ray dalam dataset. Oleh karena itu, permasalahan tersebut sangat menantang dan pengembangan algoritma untuk mendeteksi penyakit toraks seperti pneumonia akan meningkatkan aksesibilitas pengaturan klinis di daerah-daerah. Dalam studi ini, kami mengevaluasi kinerja berbagai varian model CNN yang telah dilatih sebelumnya, diikuti oleh berbagai pengklasifikasi untuk mengklasifikasikan X-ray paru abnormal dan normal. Kontribusi dari studi ini adalah sebagai berikut: (a) studi analitis komparatif dari model CNN VGG16 yang telah dilatih sebelumnya sebagai pengekstraksi fitur untuk menganalisis X-ray paru balita, (b) evaluasi model CNN yang telah dilatih sebelumnya dengan penyesuaian hiperparameter dari pengklasifikasi terbaik yang dianalisis untuk memperoleh akurasi identifikasi yang baik, (c) membangun aplikasi identifikasi pneumonia sederhana pada balita di mana hasilnya divalidasi dengan analisis dokter dan data ground truth.

Struktur artikel ini dijelaskan sebagai berikut: Bab 2, terdapat kajian pustaka dan dasar teori. Bab 3, terdapat metodologi, penjelasan mengenai detail yang relevan dengan dataset, arsitektur CNN VGG16, pengaturan eksperimen untuk eksperimen yang dilakukan pada berbagai varian model CNN pra-terlatih, metode evaluasi dan validasi. Bab 4, terdapat Hasil dan Pembahasan. Bab 5, Kesimpulan dan Saran.

2. KAJIAN PUSTAKA

Penelitian tentang deteksi pneumonia dan Covid-19 berbasis citra X-ray telah menggunakan berbagai metode Convolutional Neural Network (CNN) dengan hasil yang bervariasi. Metode Deep Residual Network dengan Optimizer Adam yang digunakan oleh Prayogi P. Illahi, Hilman Fauzi, dan Thomhert S. Siadari pada tahun 2022 mencapai akurasi 87,7% dengan nilai loss 1,8% [10]. Pada tahun yang sama, Indah Monisa Firdiantika dan Yessi Jusman menggunakan arsitektur VGG16 dan berhasil mencapai akurasi 91,2% [11]. Septy Aminatul Khoiriyah, Arif Basofi, dan Arna Fariza pada tahun 2020 menggunakan CNN dengan 3 hidden layer dan memperoleh akurasi 83,38% dengan augmentasi, dan 80,25% tanpa augmentasi [12]. Rogelio Ruzcko dan rekan-rekan pada tahun 2020

menggunakan model VGG32 untuk klasifikasi X-ray dan mencapai akurasi sekitar $\pm 90\%$ [13]. Ege Kesim, Zumray Dokur, dan Tamer Olmez pada tahun 2019 menggunakan CNN dengan ukuran citra yang lebih kecil, yaitu 128x128 piksel, dan memperoleh akurasi 86% [14]. Raheel Siddiq pada tahun 2019 menggunakan CNN dengan 18 lapisan serta Optimizer Adam, mencapai akurasi 94,3% dan sensitivitas 99% [15].

Dari hasil penelitian di atas, dapat disimpulkan bahwa penggunaan metode dan arsitektur CNN yang berbeda mempengaruhi tingkat akurasi yang dicapai. Arsitektur yang lebih dalam, seperti CNN dengan 18 lapisan yang digunakan oleh Raheel Siddiq, cenderung menghasilkan akurasi yang lebih tinggi (94,3%) dibandingkan arsitektur dengan jumlah lapisan yang lebih sedikit, seperti CNN dengan 3 hidden layer yang digunakan oleh Septy Aminatul Khoiriyah (83,38% dengan augmentasi). Selain itu, penggunaan teknik augmentasi dan optimizer seperti Adam juga berkontribusi pada peningkatan akurasi. Studi literatur dapat dilihat pada Tabel 1.

Tabel 1. Studi Literatur

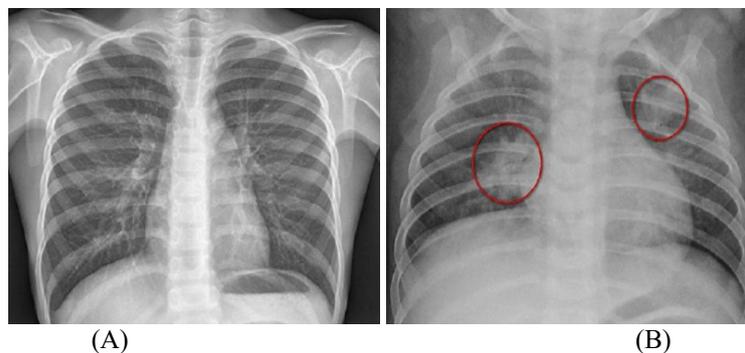
No	Judul	Tahun	Penulis	Metode	Hasil
1	Klasifikasi Penyakit Pneumonia Dan Covid-19 Berbasis Citra X-Ray Menggunakan Arsitektur Deep Residual Network	2022	Prayogi P. Illahi, Hilman Fauzi, Thomhert S. Siadari	Deep Residual Network, Optimizer Adam	Akurasi 87,7%, loss 1,8%
2	Pneumonia detection in chest X-ray images using convolutional neural network	2022	Indah Monisa Firdiantika, Yessi Jusman	VGG16	Akurasi 91,2%
3	Convolutional Neural Network for Automatic Pneumonia Detection in Chest Radiography	2020	Septy Aminatul Khoiriyah, Arif Basofi, Arna Fariza	CNN 3 hidden layer	Akurasi 83,38% dengan augmentasi, 80,25% tanpa augmentasi
4	CNN Based Learning Model Chest X-ray Health X-ray Classification Using Tensorflow	2020	Rogelio Ruzcko, Tobias, Luigi, Carlo M. De Jesus	VGG32	Akurasi $\pm 90\%$
5	X-ray Chest Image Classification by A Small-Sized Convolutional Neural Network	2019	Ege Kesim, Zumray Dokur, Tamer Olmez	CNN dengan ukuran citra 128x128 piksel	Akurasi 86%
6	Automated Pneumonia Diagnosis using a Customized Sequential Convolutional Neural Network	2019	Raheel Siddiq	CNN 18 lapisan, Optimizer Adam	Akurasi 94,3%, sensitivitas 99%

Namun, model dengan lebih banyak lapisan biasanya memerlukan waktu yang lebih lama untuk pelatihan dan inferensi. Sebagai contoh, CNN dengan 18 lapisan mungkin memerlukan waktu yang lebih lama dibandingkan CNN dengan 3 hidden layer. Oleh karena itu, pemilihan arsitektur CNN harus mempertimbangkan keseimbangan antara akurasi yang diinginkan dan efisiensi waktu yang dibutuhkan. Tantangan pada penelitian ini adalah menggunakan CNN dengan beberapa variasi parameter untuk mendapatkan model CNN yang dapat melakukan komputasi dengan cepat dan

akurat. Ini termasuk menyesuaikan jumlah epoch, ukuran dataset, resolusi gambar, dan jumlah hidden layer untuk mencapai kinerja optimal dalam hal akurasi dan waktu komputasi.

2.1 Pneumonia Balita

Pneumonia merupakan masalah kesehatan global yang signifikan karena tingginya angka kematian, baik di negara berkembang maupun di negara maju seperti Amerika Serikat, Kanada, dan negara-negara Eropa. Di Amerika Serikat, terdapat sekitar dua hingga tiga juta kasus pneumonia per tahun dengan angka kematian rata-rata mencapai 45.000 orang. Di Indonesia, angka kematian pneumonia pada balita diperkirakan mencapai 21%, dengan angka kejadian pneumonia pada bayi sebesar 2,2% dan pada balita sebesar 3%. Angka kematian pneumonia pada bayi mencapai 29,8%, sedangkan pada balita sebesar 15,5% (Riset Kesehatan Dasar, 2007). Data dari Profil Kesehatan Indonesia tahun 2005 menunjukkan terdapat 600.720 balita penderita pneumonia, dengan 155 anak meninggal sebelum usia satu tahun dan 49 anak meninggal pada usia satu hingga empat tahun [16]. Di rumah sakit, pneumonia termasuk dalam daftar sepuluh penyakit penyebab kematian pada pasien rawat inap dengan persentase sebesar 2,92% dari seluruh kematian [17].



Gambar 1. (A) Rontgen Paru-Paru Normal. (B) Rontgen Paru-Paru yang Terdeteksi Pneumonia.

Pneumonia memiliki risiko tinggi terhadap penyakit-penyakit yang berkaitan dengan ketidakmatangan Sistem Saraf Pusat (SSP) dan paru-paru, seperti aspirasi pneumonia akibat refleks menghisap, menelan, dan batuk yang belum sempurna serta sindrom gangguan pernapasan idiopatik (penyakit membran hialin). Klasifikasi Pneumonia pada Balita dapat dilihat pada Gambar 1, sedangkan keterangannya berada pada Tabel 2.

Tabel 2. Klasifikasi Pneumonia pada Balita

Kelompok Umur	Kriteria Pneumonia	Gejala Klinis
> 2 bulan sampai < 5 tahun	Batuk Bukan Pneumonia (Normal)	Tidak ada nafas cepat dan tidak ada tarikan dinding dada bagian bawah
	Pneumonia (Pneumonia Ringan)	Adanya nafas cepat dan tidak ada tarikan dinding dada bagian bawah ke dalam
	Pneumonia Berat (Pneumonia Berat)	Adanya nafas cepat dan adanya tarikan dinding dada bagian bawah kedalam
> 1 bulan sampai < 2 tahun	Bukan Pneumonia (Normal)	Tidak ada nafas cepat dan tidak ada tarikan dinding dada bagian bawah kedalam yang kuat
	Pneumonia Berat (Pneumonia Berat)	Adanyan nafas cepat dan tarikan dinding dada bagian bawah ke dalam yang kuat

2.2 Convolution Neural Network

Penggunaan deep learning dalam diagnosis klinis dan citra medis telah meningkat pesat; secara khusus, CNN dapat dianggap sebagai jenis jaringan neural multi-layer yang dibangun untuk langsung mengidentifikasi pola visual dalam citra piksel dengan pra-pemrosesan minimal. Arsitektur CNN dapat dipihat pada Gambar 2. CNN memiliki banyak kelebihan, seperti kemampuan untuk mengekstrak fitur yang signifikan dari [17]. Peneliti telah mengusulkan berbagai jaringan dalam CNN untuk mencapai klasifikasi citra [18], dan segmentasi citra [19]. Selain menyelesaikan masalah

komputer visi alami, CNN juga sangat berhasil dan efisien dalam menyelesaikan masalah medis, seperti deteksi kanker payudara [20], segmentasi tumor otak [21], mendiagnosis penyakit Alzheimer [22]. Model CNN memiliki jutaan parameter yang dapat dilatih yang memerlukan kekuatan komputasi yang substansial, dan konsumsi waktu yang tinggi [23]. Selain itu, ketika ukuran dataset yang digunakan kecil, model-model ini mungkin overfit data pelatihan, menghasilkan akurasi klasifikasi yang buruk.

I. Feature Learning

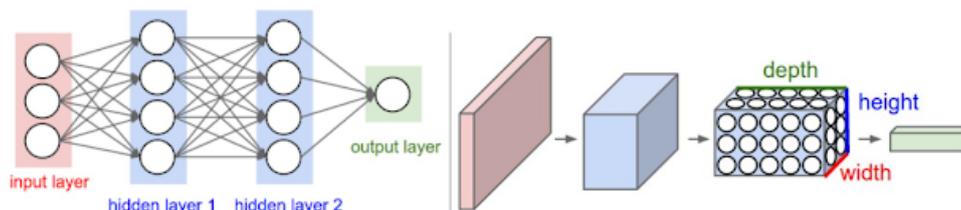
Lapisan ini berguna untuk mentranslasikan input menjadi fitur berdasarkan ciri input tersebut. Proses ini disebut "encoding" dari sebuah gambar menjadi fitur yang berupa angka-angka yang merepresentasikan gambar tersebut. Lapisan ini terdiri dari dua bagian, yaitu convolutional layer dan pooling layer.

1. *Convolutional Layer*: menghitung output dari neuron yang terhubung ke daerah lokal dalam input. Setiap neuron dalam lapisan ini menghitung produk titik antara bobot mereka dan wilayah kecil yang terhubung ke dalam volume input.
2. *Rectified Linear Unit (ReLU)*: menghilangkan vanishing gradient dengan cara menerapkan fungsi aktivasi element sebagai $f(x) = \max(0, x)$ [1].
3. *Pooling Layer*: mengurangi dimensi dari feature map, sehingga mempercepat komputasi dan mengatasi overfitting. Ada dua jenis pooling, yaitu Max Pooling dan Average Pooling. Max Pooling untuk menentukan nilai maksimum tiap pergeseran filter, sementara Average Pooling akan menentukan nilai rata-ratanya [24].

II. Classification

Lapisan ini berguna untuk mengklasifikasikan tiap neuron yang telah diekstraksi fitur sebelumnya. Lapisan ini terdiri dari dua bagian, yaitu flatten dan fully connected layer.

1. *Flatten*: membentuk ulang fitur menjadi sebuah vektor agar bisa digunakan sebagai input dari fully-connected layer.
2. *Fully-Connected Layer*: menghitung skor kelas dan mengolah data sehingga bisa diklasifikasikan. Lapisan ini memiliki neuron yang secara keseluruhan terhubung dan mengoperasikan produk dot. Lapisan Fully-Connected biasanya digunakan pada metode Multi Layer Perceptron dan bertujuan untuk mengolah data sehingga bisa diklasifikasikan [37].



Gambar 2. Arsitektur CNN¹.

3. METODE PENELITIAN

3.1 Kerangka Konsep

Pada sub bab ini memuat kerangka konsep penelitian yang dilaksanakan.

Kerangka konsep penelitian pada Gambar 3 dapat diuraikan pada sub-sub bab berikut:

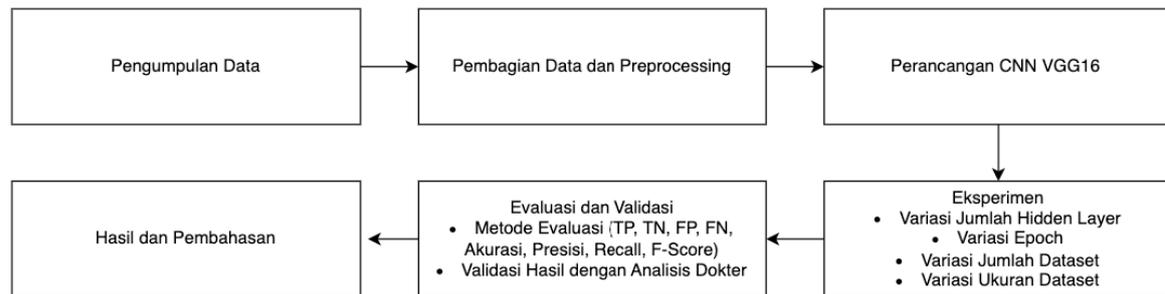
3.2 Pengumpulan Data

Penelitian ini menggunakan data sekunder yang bersumber dari dataset publik, yaitu Chest X-Ray Images (Pneumonia) yang diambil dari situs Kaggle². Dataset ini terdiri dari 5.863 gambar X-

¹<https://cs231n.github.io/convolutional-networks>

²<https://www.kaggle.com/datasets/paultimothymooney/chest-xray-pneumonia>

ray yang terbagi dalam dua kategori: pneumonia dan normal. Gambar-gambar tersebut berasal dari pasien balita yang dirawat di Guangzhou Women and Children's Medical Center, Guangzhou, China.



Gambar 3. Kerangka Konsep Penelitian.

Karakteristik gambar dalam dataset ini meliputi resolusi yang bervariasi dengan format gambar yang umumnya berupa grayscale. Untuk keperluan penelitian ini, gambar-gambar tersebut telah diubah ukurannya menjadi 224x224 piksel agar sesuai dengan kebutuhan input model Convolutional Neural Network (CNN) yang digunakan. Gambar-gambar ini telah dikategorikan oleh tenaga medis profesional berdasarkan adanya indikasi pneumonia atau kondisi paru-paru yang normal. Kategori pneumonia juga mencakup berbagai tingkat keparahan penyakit, terdiri dari pneumonia ringan dan berat, sehingga memberikan variasi yang signifikan dalam data.

3.3 Pembagian Data dan Preprocessing

Pada penelitian ini, *dataset* dibagi menjadi tiga bagian utama: data pelatihan (*training*), data uji (*testing*), dan data validasi, sebelum kemudian diuji dengan algoritma CNN. Sebelum data citra/gambar digunakan dalam model CNN, dilakukan preprocessing untuk memastikan data siap diolah oleh model. Langkah-langkah preprocessing yang dilakukan meliputi:

Resize dan Reshape. Langkah ini dilakukan untuk mentransformasi citra menjadi ukuran yang berbeda dari ukuran aslinya. Umumnya, resize digunakan untuk mengurangi ukuran citra agar biaya komputasi saat pengolahan data oleh model dapat diminimalkan. Dalam penelitian ini, semua citra diresize dan direshape menjadi ukuran panjang 244 piksel dan lebar 244 piksel.

Pembagian Data. Setelah preprocessing, dataset dibagi dengan proporsi 90% untuk data pelatihan (*training*) dan 10% untuk data uji (*testing*). Rincian pembagian data yaitu: Data training: 5.216 gambar, Data testing: 624 gambar, Data validasi: 8 citra, Data validasi dokter: 50 gambar. Setiap bagian data ini terdiri dari dua kategori, yaitu "Normal" dan "Pneumonia".

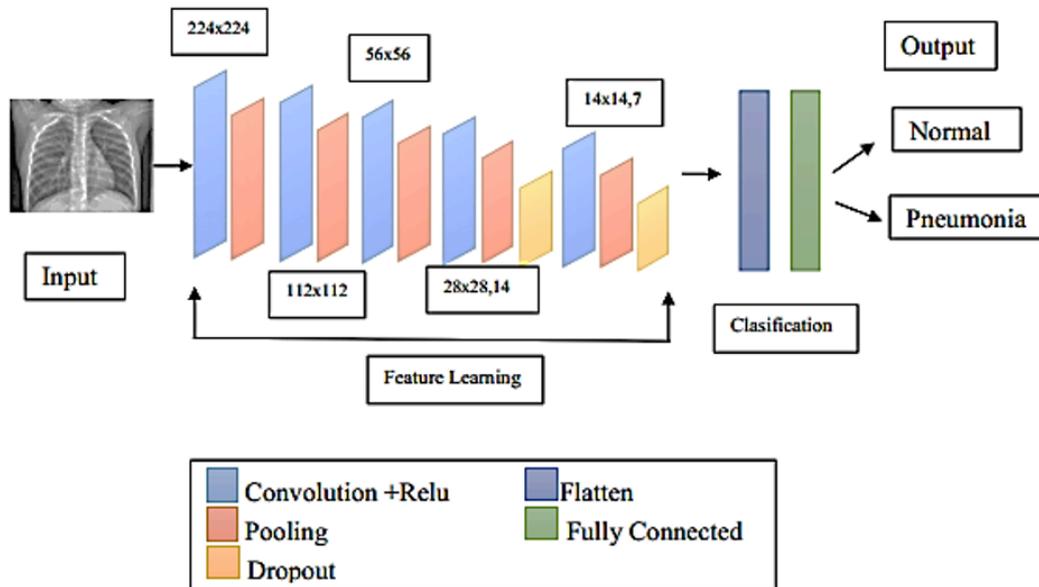
Keseimbangan Data dan Ketidakseimbangan Data. Ketidakseimbangan data dalam klasifikasi dapat menimbulkan masalah, seperti tingginya akurasi model yang disebabkan oleh prediksi yang selalu cenderung ke kelas mayoritas. Akibatnya, rasio perbandingan yang tinggi antara kelas mayoritas dan minoritas dapat menyebabkan model mengabaikan data dari kelas minoritas. Dataset ini sangat tidak seimbang karena jumlah gambar pneumonia jauh melebihi jumlah gambar normal. Situasi ini umum terjadi dalam data medis. Untuk mengatasi ketidakseimbangan data, diterapkan teknik augmentasi data guna memperbesar ukuran kelas minoritas (gambar normal) agar performa model dapat dioptimalkan dan overfitting dihindari. Augmentasi data juga tidak mempengaruhi distribusi label dalam dataset asli dan meningkatkan variasi data (*variance*).

3.4 Perancangan CNN

Setelah dilakukan pemeriksaan atas keseimbangan data dan penerapan undersampling atau oversampling, selanjutnya dilakukan perancangan CNN seperti pada Gambar 4. Dalam penelitian ini, metode optimasi yang digunakan adalah Adam. Data input terdiri dari 5000 gambar yang dipilih secara acak dari himpunan data latih. Setiap gambar melalui beberapa lapisan tersembunyi (*hidden layers*) dengan rincian sebagai berikut:

1. **Hidden Layer Pertama:** Lapisan ini terdiri dari operasi konvolusi, aktivasi ReLU, dan pooling. Konvolusi dilakukan dengan kernel berukuran 4×4 dan stride 2, menghasilkan

feature map berukuran 224×224 dengan 64 filter Conv2D. Selanjutnya, feature map diaktivasi menggunakan fungsi ReLU. Setelah aktivasi, dilakukan maksimum pooling dengan kernel 4×4 dan stride 2, menghasilkan 16 feature map berukuran 112×112 (MaxPooling2D 64).



Gambar 4. Usulan CNN VGG16 untuk Identifikasi Data Rontgen X-ray.

2. **Hidden Layer Kedua:** Operasi di lapisan kedua mirip dengan lapisan pertama, termasuk konvolusi dengan kernel 4×4 dan stride 2, menghasilkan feature map berukuran 112×112 dengan 128 filter Conv2D. Feature map diaktivasi menggunakan fungsi ReLU dan diikuti dengan maksimum pooling dengan kernel 4×4 dan stride 2, menghasilkan 16 feature map berukuran 56×56 (MaxPooling2D 128).
3. **Hidden Layer Ketiga:** Lapisan ini juga mengikuti pola yang sama dengan konvolusi menghasilkan feature map berukuran 56×56 dengan 256 filter Conv2D. Setelah aktivasi ReLU dan maksimum pooling (kernel 4×4 , stride 2), outputnya adalah 16 feature map berukuran 28×28 (MaxPooling2D 512).
4. **Hidden Layer Keempat:** Operasi konvolusi menghasilkan feature map berukuran 28×28 dengan 256 filter Conv2D. Setelah aktivasi ReLU dan maksimum pooling (kernel 4×4 , stride 2), outputnya adalah 16 feature map berukuran 14×14 (MaxPooling2D 512). Lapisan ini juga menggunakan dropout untuk mencegah overfitting.
5. **Hidden Layer Kelima:** Konvolusi menghasilkan feature map berukuran 14×14 dengan 512 filter Conv2D. Setelah aktivasi ReLU dan maksimum pooling (kernel 4×4 , stride 2), outputnya adalah 16 feature map berukuran 7×7 (MaxPooling2D 512). Dropout juga diterapkan di sini.

Setelah melalui seluruh lapisan tersembunyi, feature learning dari lapisan terakhir diflatten menjadi vektor dan dimasukkan ke dalam lapisan klasifikasi. Output dari lapisan klasifikasi untuk setiap batch digunakan untuk menghitung total nilai loss menggunakan cross entropy loss. Proses dari input hingga penghitungan output ini disebut forward phase. Setelah forward phase, dilakukan backward phase untuk menghitung gradien setiap parameter yang dioptimasi, yaitu bobot dan bias.

3.5 Eksperimen

Dalam perancangan CNN perlu mengatur nilai hyperparameter seperti learning rate, epoch, loss function, optimizer, dan sebagainya. Kemudian melalui proses training, testing dan validasi. Dalam

penelitian ini, kami menggunakan PC dengan spesifikasi sebagai berikut: Sistem operasi yang digunakan adalah Windows 10 Pro 64-bit (versi 10.0, Build 10240) dengan build number 10240.th1_st1.170427-1347. Komputer ini dilengkapi dengan prosesor Intel(R) Core (TM) i5-2520M CPU yang memiliki kecepatan 2.50GHz dan terdiri dari 4 core (CPUs), masing-masing berjalan pada frekuensi sekitar 2.5GHz. Setelah perancangan CNN, tahap selanjutnya adalah proses training, testing, dan validasi.

Proses Training. Proses training merupakan tahap krusial dalam identifikasi penyakit pneumonia pada balita menggunakan citra X-ray. Citra yang digunakan dalam proses training memiliki ukuran yang seragam, yaitu 244x244 piksel, untuk memastikan konsistensi selama pelatihan. Dataset yang digunakan mencakup 5.722 gambar yang akan dieksekusi dengan algoritma CNN untuk ekstraksi fitur.

Selama proses training, dataset dibagi menjadi pasien normal (1.341 gambar) dan pasien pneumonia (3.875 gambar). Proses ini melibatkan 15 epoch dengan batch size sebesar 4 dan target size 244. Algoritma CNN dilatih dengan arsitektur VGG16, di mana data citra melalui beberapa hidden layer yang terdiri dari operasi konvolusi, aktivasi, dan pooling. Pada setiap konvolusi, kernel berukuran 4x4 dengan stride 2 digunakan, dan feature map diaktivasi menggunakan fungsi ReLU dan Adam. Maximum pooling dengan kernel 4x4 dan stride 3 diterapkan setelah aktivasi.

Setelah melewati lima hidden layer, feature map masuk ke classification layer. Output dari layer ini digunakan untuk menghitung nilai loss menggunakan fungsi cross entropy loss, dalam tahap yang disebut forward phase. Setelah forward phase, backward phase dilakukan untuk menghitung gradien setiap parameter yang akan dioptimasi, seperti weight dan bias, menggunakan algoritma optimasi Adam. Satu epoch terdiri dari satu kali proses dari forward phase hingga backward pada seluruh data. Selama training, CNN mempelajari setiap gambar dalam folder training satu per satu, mengamati grayscale, ukuran, dan model. Data training yang ditampilkan meliputi waktu proses training, training loss, dan akurasi training, sehingga setiap layer atau epoch dapat dievaluasi.

Proses Testing. Setelah pelatihan model selesai, pertumbuhan nilai loss pada data uji diamati dari awal hingga akhir pelatihan untuk menentukan kapan model mulai mengalami overfitting dan kapan nilai loss mencapai minimum. Model CNN dengan nilai loss minimum pada data uji dipilih untuk evaluasi lebih lanjut guna menilai performanya dalam memprediksi data.

3.6 Evaluasi dan Validasi

3.6.1 Evaluasi

Model yang telah dilatih menggunakan data latih kemudian dievaluasi. Evaluasi dilakukan dengan menggunakan confusion matrix, matriks klasifikasi yang mencakup precision dan recall untuk setiap kelas, serta akurasi model, untuk menilai kemampuan model dalam mengklasifikasikan data pada setiap kelas. Selain itu, waktu yang dibutuhkan untuk pelatihan model juga dianalisis. Selanjutnya, dilakukan pengenalan dengan klasifikasi yang telah ditentukan untuk memudahkan prediksi pasien normal dan pasien pneumonia.

Setelah mendapatkan data hasil pengujian, langkah selanjutnya adalah menentukan nilai evaluasi kinerja model menggunakan matriks konfusi. Matriks ini digunakan untuk menganalisis kinerja model klasifikasi setelah pengujian. Evaluasi kinerja digunakan untuk mengevaluasi dan menganalisis kinerja yang lebih baik modelnya, yang meliputi Akurasi, Tingkat kesalahan, Tingkat presisi, Recall, Spesifisitas, dan F-Measure. Untuk itu kita perlu memahami definisi dari empat jenis data berikut:

TP (True Positive): jumlah data positif aktual yang diprediksi positif (gambar Pneumonia diidentifikasi sebagai pneumonia).

TN (True Negative): jumlah data negatif sebenarnya yang diprediksi negatif (gambar normal diidentifikasi sebagai normal atau sehat).

FP (False Positive): jumlah data negatif sebenarnya yang diprediksi positif (gambar normal salah diidentifikasi sebagai pneumonia).

FN (False Negative): jumlah data positif aktual yang diprediksi negatif (gambar Pneumonia salah diidentifikasi sebagai normal atau sehat).

Keempat jenis data tersebut digunakan sebagai acuan metrik evaluasi sebagai berikut:

Akurasi (Accuracy). Akurasi adalah rasio prediksi data yang benar terhadap keseluruhan data uji. Ini adalah kinerja yang paling intuitif ukuran. Ini menjawab pertanyaan, “Berapa persentase dari prediksi gambar yang benar untuk normal dan kelas pneumonia dari semua data uji”.

$$\text{Accuracy} = \frac{TN+TP}{TN+TP+FN+FP} \times 100\% \quad (1)$$

Tingkat Kesalahan (Error Rate). Tingkat kesalahan menghitung jumlah semua data yang diprediksi salah dari semua gambar uji total. Terbaik tingkat kesalahan adalah 0,0, sedangkan yang terburuk adalah 1,0.

$$\text{Error Rate} = \frac{FP+FN}{FP+FN+TP+TN} \times 100\% \quad (2)$$

Presisi (Precision). Presisi adalah rasio prediksi positif sejati dibandingkan dengan hasil positif prediksi keseluruhan. Presisi menjawab pertanyaan, “Berapa persen citra normal dari keseluruhan prediksi citra normal”. Itu presisi terbaik adalah 1,0, dan yang terburuk adalah 0,0.

$$\text{Presisi} = \frac{TP}{TP+FP} \times 100\% \quad (3)$$

Sensitivitas (Recall). Recall menghitung jumlah citra prediktif positif dan positif dibandingkan dengan total citra positif dan data positif. Nilai sensitivitas terbaik adalah 1,0, sedangkan yang terburuk adalah 0,0.

$$\text{Recall} = \frac{TP}{TP+FN} \times 100\% \quad (4)$$

Skor-F (F-Measure). F-Measure, adalah perbandingan rata-rata presisi dan daya ingat. F-Measure adalah yang paling banyak metrik yang umum digunakan pada masalah klasifikasi tidak seimbang. Jika mengingat dan presisi memperoleh yang baik nilai F-measure juga memperoleh nilai yang baik.

$$\text{F-Measure} = \frac{2 \times \text{Recall} \times \text{Presisi}}{\text{Recall} + \text{Presisi}} \times 100\% \quad (5)$$

3.6.2 Confusion Matrix

Tingkat keakuratan dari hasil pengujian model didapat dari perhitungan confusion matrix terhadap citra chest X-ray. Percobaan ini melibatkan variasi jumlah hidden layer, yaitu 1, 3, dan 5, untuk memperoleh hasil yang komprehensif.

4. HASIL DAN PEMBAHASAN

Pada penelitian ini, dilakukan tiga set percobaan dengan variasi parameter untuk mengevaluasi pengaruh jumlah data, epoch, dan ukuran gambar terhadap akurasi pelatihan, akurasi validasi, dan waktu pelatihan pada arsitektur Convolutional Neural Network (CNN) seperti yang ditunjukkan pada Tabel 3. Percobaan pertama (nomor 1-5) memvariasikan jumlah data sementara epoch dan ukuran gambar dijaga konstan pada 5 dan 224 x 224. Hasil menunjukkan bahwa peningkatan jumlah data secara umum meningkatkan akurasi validasi. Akurasi validasi tertinggi yaitu 0.9167 dicapai pada percobaan nomor 5 dengan jumlah data terbesar, yaitu 1800 data normal dan 3200 data pneumonia. Peningkatan jumlah data memungkinkan model untuk lebih mengenali pola sehingga meningkatkan performa pada data validasi, meskipun menyebabkan peningkatan waktu pelatihan, dengan waktu terlama yaitu 11 jam 41 menit pada percobaan nomor 5.

Percobaan kedua (nomor 6-9) memvariasikan epoch sementara jumlah data dan ukuran gambar dijaga konstan pada 800 data normal dan 1200 data pneumonia serta 224 x 224. Hasil menunjukkan bahwa peningkatan jumlah epoch umumnya meningkatkan akurasi validasi. Akurasi validasi tertinggi yaitu 0.9615 dicapai pada percobaan nomor 9 dengan epoch sebanyak 15. Peningkatan epoch memberikan model lebih banyak kesempatan untuk belajar dan menyempurnakan bobot, namun juga meningkatkan waktu pelatihan secara signifikan, yaitu 27 jam 9 menit pada percobaan nomor 9.

Percobaan ketiga (nomor 10-13) memvariasikan ukuran gambar sementara epoch dan jumlah data dijaga konstan pada 5 dan 800 data normal serta 1200 data pneumonia. Hasil menunjukkan bahwa ukuran gambar 244 x 244 menghasilkan akurasi validasi tertinggi yaitu 0.9443 pada percobaan nomor 12. Ukuran gambar yang terlalu kecil seperti 64 x 64 menghasilkan akurasi validasi yang rendah (0.6254 pada percobaan nomor 10) karena kehilangan detail penting pada gambar. Sebaliknya, ukuran gambar yang terlalu besar seperti 512 x 512 pada percobaan nomor 13 menghasilkan akurasi validasi yang lebih rendah (0.8974) dan waktu pelatihan yang sangat lama (26 jam 32 menit). Hal ini disebabkan oleh beban komputasi yang lebih tinggi dan kemungkinan overfitting karena model menangani lebih banyak fitur yang tidak relevan.

Tabel 3. Perbandingan Hasil Akurasi Training, Akurasi Validasi dan Waktu Training berdasarkan Variasi Epoch, Jumlah Data, dan Ukuran Gambar

No	Hidden Layer	Epoch	Jumlah Data	Ukuran Gambar	Akurasi Training	Akurasi Validasi	Waktu Training
1	5	5	Normal 300 Pneumonia 700	224 x 224	0.9504	0.8771	2 Jam 41 Menit
2	5	5	Normal 800 Pneumonia 1200	224 x 224	0.9658	0.8915	3 Jam 53 Menit
3	5	5	Normal 900 Pneumonia 2100	224 x 224	0.9504	0.8997	7 Jam 16 Menit
4	5	5	Normal 1000 Pneumonia 3000	224 x 224	0.9612	0.9009	8 Jam 39 Menit
5	5	5	Normal 1800 Pneumonia 3200	224 x 224	0.9557	0.9167	11 jam 41 menit
6	5	3	Normal 800 Pneumonia 1200	224 x 224	0.9523	0.8821	3 Jam 54 Menit
7	5	5	Normal 800 Pneumonia 1200	224 x 224	0.9471	0.8920	4 Jam 37 Menit
8	5	10	Normal 800 Pneumonia 1200	224 x 224	0.9571	0.9020	25 Jam 20 Menit
9	5	15	Normal 800 Pneumonia 1200	224 x 224	0.9677	0.9615	27 Jam 09 Menit
10	5	5	Normal 800 Pneumonia 1200	64x64	0.9207	0,6254	1 Jam 32 Menit
11	5	5	Normal 800 Pneumonia 1200	128x128	0,9535	0,9185	4 Jam 2 Menit
12	5	5	Normal 800 Pneumonia 1200	244x244	0,9402	0,9443	5 Jam 41 Menit
13	5	5	Normal 800 Pneumonia 1200	512x512	0,9018	0,8974	26 Jam 32 Menit

Secara keseluruhan, penelitian ini menunjukkan bahwa meningkatkan jumlah data pelatihan cenderung meningkatkan akurasi validasi karena model dapat belajar dari lebih banyak contoh, namun memerlukan waktu pelatihan yang lebih lama. Menambah jumlah epoch meningkatkan akurasi validasi hingga titik tertentu karena model memiliki lebih banyak iterasi untuk menyempurnakan pembelajaran, namun juga meningkatkan waktu pelatihan secara signifikan. Sementara itu, ukuran gambar optimal (244 x 244) memberikan akurasi validasi tertinggi. Ukuran gambar yang terlalu kecil mengurangi akurasi karena informasi yang hilang, sementara ukuran

gambar yang terlalu besar meningkatkan beban komputasi dan cenderung overfitting, menghasilkan akurasi yang lebih rendah. Penelitian ini menunjukkan pentingnya menyeimbangkan jumlah data, epoch, dan ukuran gambar untuk mendapatkan performa model terbaik dengan efisiensi waktu pelatihan yang optimal.

Dalam percobaan lanjutan ini, kami menggunakan parameter terbaik yang diperoleh dari Tabel 3, yaitu epoch sebanyak 15, jumlah data sebesar 1800 untuk Normal dan 3200 untuk Pneumonia, serta ukuran citra 224x224 piksel. Kami memvariasikan jumlah hidden layer untuk menilai pengaruhnya terhadap akurasi training, akurasi validasi, dan waktu training. Tabel 4 menunjukkan hasil dari tiga konfigurasi jaringan yang berbeda berdasarkan jumlah hidden layer yang digunakan: satu hidden layer, tiga hidden layer, dan lima hidden layer. Masing-masing konfigurasi diuji dengan epoch yang sama yaitu 15 dan menggunakan set data yang konsisten.

Pada percobaan dengan satu hidden layer, hasil akurasi training mencapai 0,9399 dan akurasi validasi sebesar 0,9038 dengan waktu training selama 5 jam. Ini menunjukkan bahwa jaringan dengan satu hidden layer sudah mampu mencapai akurasi yang cukup tinggi namun memerlukan waktu training yang relatif singkat dibandingkan dengan konfigurasi lain. Percobaan dengan tiga hidden layer meningkatkan akurasi training menjadi 0,9446 dan akurasi validasi menjadi 0,9375. Waktu training meningkat menjadi 7 jam. Ini menunjukkan bahwa menambah jumlah hidden layer dapat meningkatkan akurasi baik pada training maupun validasi, meskipun dengan peningkatan waktu training yang masih dapat diterima. Konfigurasi dengan lima hidden layer menghasilkan akurasi training yang sama dengan konfigurasi tiga hidden layer yaitu 0,9446, namun akurasi validasi sedikit lebih tinggi yaitu 0,9410. Waktu training untuk konfigurasi ini mencapai 13 jam, yang merupakan waktu paling lama di antara ketiga konfigurasi. Peningkatan akurasi validasi meskipun kecil, menunjukkan bahwa menambah hidden layer lebih banyak mungkin tidak memberikan peningkatan yang signifikan dalam akurasi setelah titik tertentu, tetapi secara substansial meningkatkan waktu training.

Dengan penambahan jumlah hidden layer memang dapat meningkatkan akurasi validasi, tetapi dengan trade-off terhadap waktu training yang lebih lama. Konfigurasi dengan tiga hidden layer menunjukkan keseimbangan terbaik antara akurasi dan waktu training. Konfigurasi lima hidden layer menawarkan sedikit peningkatan dalam akurasi validasi, tetapi dengan waktu training yang jauh lebih tinggi, yang mungkin tidak praktis untuk implementasi dengan sumber daya komputasi yang terbatas.

Tabel 4. Perbandingan Hasil Akurasi Training, Akurasi Validasi, dan Waktu Training Berdasarkan Jumlah Hidden Layer pada Percobaan Lanjutan

No	Hidden Layer	Epoch	Jumlah Data	Ukuran Gambar	Akurasi Training	Akurasi Validasi	Waktu Training
1	1	15	Normal 1800 Pneumonia 3200	224 x 224	0,9399	0,9038	5 Jam
2	3	15	Normal 1800 Pneumonia 3200	224 x 224	0,9446	0,9375	7 Jam
3	5	15	Normal 1800 Pneumonia 3200	224 x 224	0,9446	0,9410	13 Jam

Selanjutnya, kami menggunakan arsitektur CNN dengan parameter optimal yang diperoleh dari Tabel 4, yakni jumlah epoch sebanyak 15, jumlah data normal sebanyak 1800 dan pneumonia sebanyak 3200, serta ukuran gambar 224x224 piksel. Untuk mengevaluasi performa model, kami menghitung metrik Akurasi, Presisi, Recall, Error Rate, dan F-Measure menggunakan persamaan yang telah dijelaskan pada sub bab 3.6.1. Hasil perhitungan ini kemudian diuraikan dalam Tabel 5.

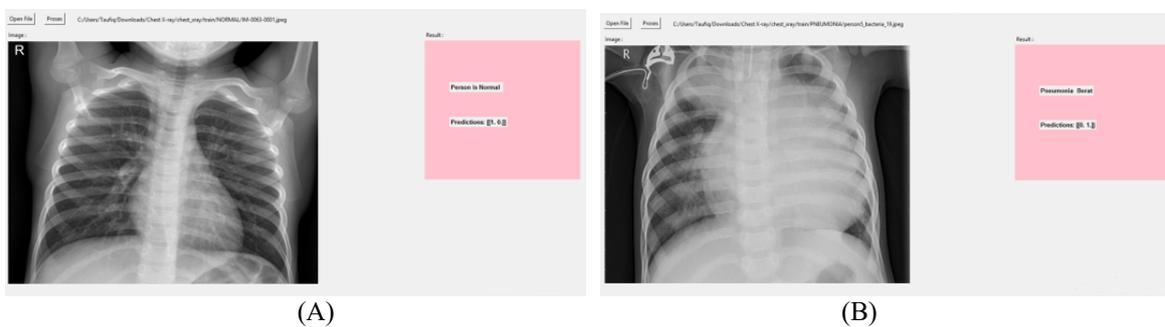
Percobaan dilakukan dengan tiga variasi jumlah hidden layer: satu, tiga, dan lima. Setiap percobaan menggunakan 50 citra chest X-ray normal dan 50 citra pneumonia untuk menguji performa model. Hasil menunjukkan bahwa peningkatan jumlah hidden layer secara konsisten meningkatkan performa model.

Pada model dengan satu hidden layer, kami memperoleh 39 True Negative (TN), 43 True Positive (TP), 11 False Positive (FP), dan 7 False Negative (FN). Ini menghasilkan akurasi sebesar

82%, presisi sebesar 84%, recall sebesar 78%, error rate sebesar 18%, dan F-measure sebesar 80,89%. Model dengan tiga hidden layer menunjukkan peningkatan performa yang signifikan dengan 43 TN, 45 TP, 7 FP, dan 5 FN. Dari hasil ini, diperoleh akurasi sebesar 88%, presisi sebesar 89%, recall sebesar 86%, error rate sebesar 12%, dan F-measure sebesar 87,47%. Selanjutnya, model dengan lima hidden layer memberikan hasil terbaik dengan 46 TN, 45 TP, 4 FP, dan 5 FN. Metrik performa untuk model ini adalah akurasi sebesar 91%, presisi sebesar 90%, recall sebesar 92%, error rate sebesar 13%, dan F-measure sebesar 90,99%.

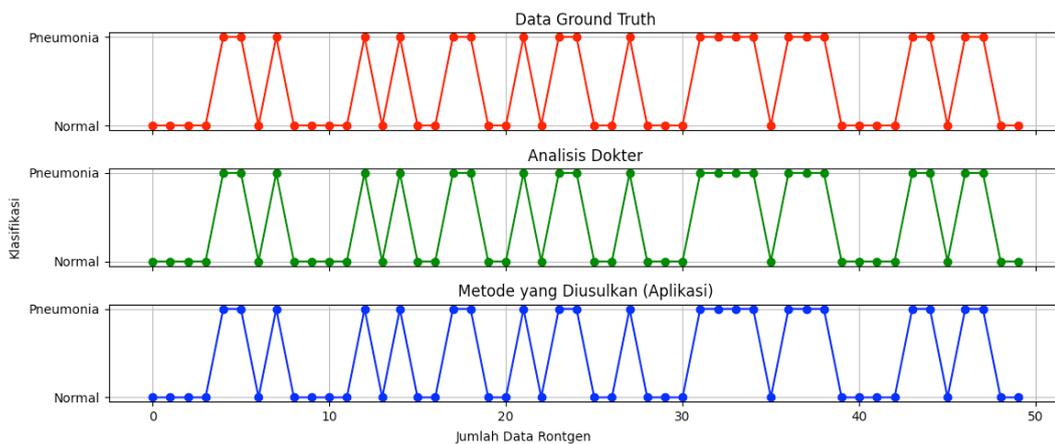
Tabel 5. Perbandingan Akurasi, Presisi, Recall, Error Rate, dan F-Measure Berdasarkan Jumlah Hidden Layer dengan Arsitektur yang Diusulkan

Data	Akurasi	Presisi	Recall	Error Rate	F-Measure
1 Hidden Layer	82 %	84%	78%	18%	80,89%
3 Hidden Layer	88%	89%	86%	12%	87,47%
5 Hidden Layer	91%	90%	92%	13%	90,99%



Gambar 5. Aplikasi Identifikasi Pneumonia dengan menggunakan Metode CNN yang diusulkan. (A) Rontgen Paru-Paru Normal. (B) Rontgen Paru-Paru yang Terdeteksi Pneumonia.

Untuk mengaplikasikan arsitektur CNN yang diusulkan, kami mengembangkan GUI Matlab yang mampu membaca dan mengidentifikasi gambar rontgen X-ray paru-paru. Gambar 5 menunjukkan aplikasi ini, dengan Gambar 5 (A) menampilkan rontgen paru-paru normal dan Gambar 5 (B) menampilkan rontgen paru-paru yang terdeteksi pneumonia.



Gambar 6. Perbandingan 50 Hasil Identifikasi Data Rontgen X-ray: Metode yang Diusulkan (Biru), Analisis Dokter (Hijau), dan Data Ground Truth (Merah).

Arsitektur CNN dengan lima hidden layer yang digunakan menunjukkan akurasi prediksi sebesar 91% (Tabel 5). Oleh karena itu, arsitektur ini dipilih untuk validasi lebih lanjut dengan analisis dokter. Identifikasi menggunakan 50 foto rontgen dada normal dan pneumonia menunjukkan hasil yang konsisten dengan analisis dokter, dengan waktu pembacaan 0,2 detik, jauh lebih cepat

dibandingkan 5-10 menit yang dibutuhkan dokter. Hasil ini menekankan bahwa metode ini akurat dan efisien untuk mendiagnosis pneumonia pada balita.

Validasi hasil identifikasi arsitektur CNN dengan analisis dokter dan data ground truth ditunjukkan pada Gambar 6. Perbandingan hasil identifikasi antara metode yang diusulkan (Biru), analisis dokter (Hijau), dan data ground truth (Merah) menunjukkan kesesuaian yang tinggi. Hal ini menunjukkan bahwa metode yang diusulkan dapat diandalkan dan memiliki tingkat keakuratan tinggi dalam mendeteksi pneumonia.

Implementasi arsitektur CNN memiliki potensi besar untuk digunakan dalam praktik medis sehari-hari, khususnya dalam diagnosis pneumonia pada balita. Dengan akurasi tinggi dan kecepatan analisis yang cepat, metode ini dapat mengurangi beban kerja dokter serta meningkatkan kualitas dan kecepatan diagnosis di rumah sakit dan klinik. Penelitian ini menunjukkan bahwa penggunaan arsitektur CNN dengan lima hidden layer adalah pendekatan efektif untuk identifikasi pneumonia berdasarkan gambar X-ray.

5. KESIMPULAN DAN SARAN

Studi ini mengeksplorasi penggunaan Convolutional Neural Network (CNN) untuk meningkatkan akurasi identifikasi pneumonia pada gambar rontgen paru-paru balita. Berdasarkan hasil percobaan, arsitektur CNN dengan 5 hidden layer menghasilkan akurasi prediksi tertinggi sebesar 91%. Identifikasi menggunakan model ini konsisten dengan analisis dokter, menunjukkan potensi untuk digunakan secara efektif dalam diagnosis cepat dan tepat. Untuk meningkatkan akurasi identifikasi lebih lanjut, disarankan untuk memperluas dataset dengan lebih banyak gambar rontgen paru-paru, termasuk kasus pneumonia yang lebih kompleks dan data normal yang lebih bervariasi. Selain itu, eksplorasi lebih lanjut terhadap optimalisasi jumlah hidden layer, fine-tuning parameter seperti jumlah epoch, learning rate, dan batch size, serta penerapan teknik augmentasi data dapat menjadi langkah-langkah strategis dalam mengembangkan model yang lebih robust. Validasi lebih lanjut dengan melibatkan lebih banyak kasus klinis dan analisis dokter juga penting untuk memastikan keandalan dan validitas model di lingkungan klinis yang lebih luas.

DAFTAR PUSTAKA

- [1] A. M. Puspitasari, S. Suhartono, and K. Kushartantya, "Sistem Pakar Berbasis Web dengan Metode Probabilitas Klasik untuk Diagnosa Penyakit Tuberkulosis Pada Manusia Dewasa," *J. Masy. Inform.*, vol. 4, no. 8, pp. 35–43, 2013.
- [2] A. Subandi and I. Ariani, "Peningkatan Pengetahuan dan Kemampuan Ibu dalam Penatalaksanaan pada balita Pneumonia dengan Pendekatan MTBS di Puskesmas Cilacap Selatan 1," *J. Pengabd. Masy. Al-Irsyad*, vol. 1, no. 2, pp. 126–133, 2019.
- [3] S. MIRHALINA, "[BOOK CHAPTER] PENANGGULANGAN PENYAKIT TIDAK MENULAR DI INDONESIA," 2023.
- [4] R. Adawiyah, "Faktor-faktor Yang Berpengaruh Terhadap Kejadian Pneumonia Pada Balita di Puskesmas Susunan Kota Bandar Lampung Tahun 2012," *J. Kedokt. Yars.*, vol. 24, no. 1, pp. 51–68, 2016.
- [5] K. Kallianos *et al.*, "How far have we come? Artificial intelligence for chest radiograph interpretation," *Clin. Radiol.*, vol. 74, no. 5, pp. 338–345, 2019.
- [6] S. Tammima, "Transfer learning using vgg-16 with deep convolutional neural network for classifying images," *Int. J. Sci. Res. Publ.*, vol. 9, no. 10, pp. 143–150, 2019.
- [7] M. Toğaçar, B. Ergen, Z. Cömert, and F. Özyurt, "A deep feature learning model for pneumonia detection applying a combination of mRMR feature selection and machine learning models," *Irbm*, vol. 41, no. 4, pp. 212–222, 2020.
- [8] A. G. Taylor, C. Mielke, and J. Mongan, "Automated detection of moderate and large pneumothorax on frontal chest X-rays using deep convolutional neural networks: A retrospective study," *PLoS Med.*, vol. 15, no. 11, p. e1002697, 2018.
- [9] T. K. Khanh Ho and J. Gwak, "Multiple feature integration for classification of thoracic disease in chest radiography," *Appl. Sci.*, vol. 9, no. 19, p. 4130, 2019.

- [10] P. P. Illahi, H. Fauzi, and T. S. Siadari, "Klasifikasi Penyakit Pneumonia Dan Covid-19 Berbasis Citra X-Ray Menggunakan Arsitektur Deep Residual Network," *eProceedings Eng.*, vol. 9, no. 4, 2022.
- [11] I. M. Firdiantika and Y. Jusman, "Pneumonia detection in chest X-ray images using convolutional neural network," in *AIP Conference Proceedings*, 2022, vol. 2499, no. 1.
- [12] S. A. Khoiriyah, A. Basofi, and A. Fariza, "Convolutional neural network for automatic pneumonia detection in chest radiography," in *2020 International Electronics Symposium (IES)*, 2020, pp. 476–480.
- [13] R. R. N. M. I. Tobias *et al.*, "CNN-based deep learning model for chest X-ray health classification using tensorflow," in *2020 RIVF International Conference on Computing and Communication Technologies (RIVF)*, 2020, pp. 1–6.
- [14] E. Kesim, Z. Dokur, and T. Olmez, "X-ray chest image classification by a small-sized convolutional neural network," in *2019 scientific meeting on electrical-electronics & biomedical engineering and computer science (EBBT)*, 2019, pp. 1–5.
- [15] R. Siddiqi, "Automated pneumonia diagnosis using a customized sequential convolutional neural network," in *Proceedings of the 2019 3rd international conference on deep learning technologies*, 2019, pp. 64–70.
- [16] S. Hartati, N. Nurhaeni, and D. Gayatri, "Faktor risiko terjadinya pneumonia pada anak balita," *J. Keperawatan Indones.*, vol. 15, no. 1, pp. 13–20, 2012.
- [17] E. Warganegara, "Pneumonia Nosokomial (Hospital-acquired, Ventilator-associated, dan Health Care-associated Penumonia)," *J. Kedokt. Univ. Lampung*, vol. 1, no. 3, pp. 612–618, 2017.
- [18] W. Gazali, H. Soeparno, and J. Ohliati, "Penerapan Metode Konvolusi Dalam Pengolahan Citra Digital," *J. Mat Stat*, vol. 12, no. 2, pp. 103–113, 2012.
- [19] R. D. Kusumanto and A. N. Tompunu, "pengolahan citra digital untuk mendeteksi obyek menggunakan pengolahan warna model normalisasi RGB," in *Seminar Nasional Teknologi Informasi & Komunikasi Terapan*, 2011, vol. 2011, pp. 1–7.
- [20] R. Rajakumari and L. Kalaivani, "Breast Cancer Detection and Classification Using Deep CNN Techniques.," *Intell. Autom. Soft Comput.*, vol. 32, no. 2, 2022.
- [21] P. Tiwari *et al.*, "Cnn based multiclass brain tumor detection using medical imaging," *Comput. Intell. Neurosci.*, vol. 2022, no. 1, p. 1830010, 2022.
- [22] A. W. Salehi, P. Baglat, B. B. Sharma, G. Gupta, and A. Upadhy, "A CNN model: earlier diagnosis and classification of Alzheimer disease using MRI," in *2020 International Conference on Smart Electronics and Communication (ICOSEC)*, 2020, pp. 156–161.
- [23] A. Y. Bequet, L. Rusyadi, and F. Fatimah, "Nilai Contrast to Noise Ratio (CNR) Radiograf Thorax PA antara menggunakan Grid dengan tanpa Menggunakan Grid," *J. Imejing Diagnostik*, vol. 6, no. 2, pp. 60–64, 2020.
- [24] I. Bakti and M. Firdaus, "Klasifikasi File Gambar Hasil X-Ray Paru-Paru Dengan Arsitektur Convolution Neural Network (CNN)," *J. Inf. Technol.*, vol. 3, no. 1, pp. 26–34.