

# KLASIFIKASI PNEUMONIA PADA CITRA X-RAY DADA MENGGUNAKAN EKSTRAKSI CIRI *CONVOLUTIONAL NEURAL NETWORK* DAN ALGORITMA *K-NEAREST NEIGHBOR*

Yusraka Dimas Al Iman<sup>1)</sup>, Septine Eka Putri<sup>2)</sup>, dan Agus Supriyanto<sup>3)</sup>

<sup>1)</sup> Program Studi Teknik Biomedis, Sekolah Tinggi Kesehatan Semarang

<sup>2)</sup> Program Studi Keselamatan dan Kesehatan Kerja, Sekolah Tinggi Kesehatan Semarang

<sup>3)</sup> Teknik Elektronika, SMK Pembangunan Nasional Purwodadi

<sup>1,2)</sup> Jl. Kolonel Warsito Sugiarto KM. 2,5 Sadeng, Gunungpati – Semarang

<sup>3)</sup> Jl. Gajah Mada No.5, Jetis Selatan, Purwodadi, Grobogan, Jawa Tengah 58111

e-mail: yusraka5@gmail.com<sup>1)</sup>, septineekap5@gmail.com<sup>2)</sup>, dan agussupriyanto.elektro@gmail.com<sup>3)</sup>

## ABSTRACT

*Pneumonia is an acute lung infection that remains one of the leading causes of death worldwide, particularly in children under five years of age and the elderly. Conventional diagnosis through chest X-ray interpretation requires high radiological expertise and is susceptible to human error, especially in regions with limited medical resources. This study proposes a two-stage automatic pneumonia classification system using Convolutional Neural Network (CNN) as an automatic feature extractor and K-Nearest Neighbor (KNN) as the final classifier on chest X-ray images. The dataset used is the publicly available Chest X-Ray Images (Pneumonia) from Kaggle, consisting of 5,863 images classified into two classes: Normal (1,583 images) and Pneumonia (4,280 images). The preprocessing pipeline includes grayscale conversion, Contrast Limited Adaptive Histogram Equalization (CLAHE), resizing to 224×224 pixels, and normalization to (0,1). A CNN architecture with three convolutional blocks (32–64–128 filters) with Batch Normalization extracts a 128-dimensional feature vector per image. The optimal K value for KNN is determined through validation experiments yielding K=5 with weighted Euclidean distance. The proposed system achieves an accuracy of 92.80%, precision of 94.12%, recall of 95.34%, F1-Score of 94.73%, specificity of 91.98%, and AUC-ROC of 0.971 on the test set, outperforming conventional methods including SVM+HOG (78.30%) and CNN end-to-end (90.45%).*

**Keywords:** chest X-ray, convolutional neural network, K-nearest neighbor, medical image classification, pneumonia detection.

## ABSTRAK

*Pneumonia merupakan infeksi akut pada paru-paru yang masih menjadi salah satu penyebab kematian tertinggi di dunia, terutama pada anak-anak di bawah usia lima tahun dan lansia. Diagnosis konvensional melalui interpretasi citra X-Ray dada memerlukan keahlian radiologis yang tinggi dan rentan terhadap kesalahan manusia, khususnya di daerah dengan keterbatasan sumber daya medis. Penelitian ini mengusulkan sistem klasifikasi pneumonia otomatis dua tahap menggunakan Convolutional Neural Network (CNN) sebagai ekstraktor ciri otomatis dan K-Nearest Neighbor (KNN) sebagai pengklasifikasi akhir pada citra X-Ray dada. Dataset yang digunakan adalah Chest X-Ray Images (Pneumonia) dari Kaggle yang terdiri dari 5.863 citra dengan dua kelas: Normal (1.583 citra) dan Pneumonia (4.280 citra). Pipeline preprocessing meliputi konversi grayscale, peningkatan kontras menggunakan Contrast Limited Adaptive Histogram Equalization (CLAHE), resize ke 224×224 piksel, dan normalisasi ke rentang (0,1). Arsitektur CNN dengan tiga blok konvolusi (32–64–128 filter) disertai Batch Normalization mengekstrak vektor fitur 128 dimensi per citra. Nilai K optimal untuk KNN ditentukan melalui eksperimen validasi menghasilkan K=5 dengan jarak Euclidean berbobot. Sistem yang diusulkan mencapai akurasi 92,80%, presisi 94,12%, recall 95,34%, F1-Score 94,73%, specificity 91,98%, dan AUC-ROC 0,971 pada data uji, mengungguli metode konvensional termasuk SVM+HOG (78,30%) dan CNN end-to-end (90,45%).*

**Kata Kunci:** citra X-Ray dada, convolutional neural network, K-nearest neighbor, klasifikasi citra medis, deteksi pneumonia.

## I. PENDAHULUAN

**P**NEUMONIA adalah infeksi akut pada jaringan paru-paru yang disebabkan oleh bakteri, virus, atau jamur. Menurut *World Health Organization* (WHO), pneumonia menyebabkan lebih dari 2,5 juta kematian per tahun secara global, dengan proporsi terbesar pada anak-anak di bawah usia 5 tahun di negara berkembang [1]. Di Indonesia, pneumonia menempati urutan ketiga penyebab kematian bayi dan balita berdasarkan data Kementerian Kesehatan Republik Indonesia tahun 2023. Tingginya angka kematian akibat

pneumonia sebagian besar disebabkan oleh keterlambatan diagnosis, terutama di daerah terpencil yang kekurangan tenaga medis spesialis.

Diagnosis pneumonia secara klinis dilakukan melalui pemeriksaan fisik, laboratorium, dan pencitraan medis, khususnya foto *rontgen* (X-Ray) dada. Interpretasi citra X-Ray oleh radiologis memerlukan keahlian tinggi dan waktu yang tidak sedikit. Pada kondisi darurat atau daerah dengan keterbatasan tenaga ahli, keterlambatan diagnosis dapat berakibat fatal. Oleh karena itu, pengembangan sistem *Computer-Aided Diagnosis* (CAD) berbasis kecerdasan buatan menjadi sangat

relevan dan mendesak [2].

Dalam dekade terakhir, deep learning, khususnya *Convolutional Neural Network* (CNN), telah merevolusi bidang pengolahan citra medis. CNN mampu mengekstrak fitur hierarkis secara otomatis dari citra tanpa rekayasa fitur manual, menghasilkan representasi yang kaya dan diskriminatif [3]. Kemampuan CNN dalam menangkap pola lokal seperti tepi, tekstur, dan struktur anatomis menjadikannya sangat sesuai untuk analisis citra medis berdimensi tinggi. Beberapa penelitian terkini menunjukkan bahwa CNN dapat mencapai akurasi setara atau bahkan melampaui radiologis berpengalaman dalam deteksi pneumonia [4].

Studi komparatif oleh Dehbozorgi dkk. (2025) menunjukkan bahwa metode ekstraksi fitur berbasis deep learning secara konsisten mengungguli pendekatan statistik dan radiomics tradisional untuk klasifikasi citra medis termasuk citra X-Ray dada, dengan latensi yang lebih rendah dan performa yang lebih tinggi [5]. Temuan ini memperkuat argumentasi penggunaan CNN sebagai ekstraktor fitur dalam penelitian ini.

Di sisi lain, algoritma *K-Nearest Neighbor* (KNN) dikenal sebagai pengklasifikasi yang sederhana namun efektif, terutama ketika dikombinasikan dengan representasi fitur yang baik. KNN bekerja berdasarkan prinsip kemiripan, di mana suatu sampel diklasifikasikan berdasarkan kelas mayoritas dari K tetangga terdekatnya dalam ruang fitur [6]. Jena dkk. (2024) membuktikan bahwa kombinasi deep feature extraction dengan fine KNN mampu meningkatkan akurasi deteksi penyakit pada citra medis secara signifikan dibanding KNN dengan fitur konvensional [7].

Penelitian Al Iman dkk. (2023) pada domain klasifikasi ikan laut menggunakan 2-Dimensional Linear Discriminant Analysis (2D-LDA) sebagai ekstraktor ciri dikombinasikan dengan KNN mencapai akurasi terbaik 93,12% pada K=9, membuktikan bahwa paradigma ekstraktor ciri yang kuat dikombinasikan dengan KNN menghasilkan performa kompetitif pada berbagai domain klasifikasi citra [8].

Meskipun CNN yang dilatih secara end-to-end dengan layer softmax/sigmoid sudah merupakan classifier tersendiri, terdapat beberapa alasan mendasar mengapa pendekatan dua tahap CNN+KNN lebih disukai dalam penelitian ini. Pertama, pada dataset berukuran sedang dengan ketidakseimbangan kelas yang signifikan (73% Pneumonia vs 27% Normal), layer softmax/sigmoid tunggal cenderung bias terhadap kelas mayoritas karena dioptimalkan melalui *cross-entropy loss* yang tidak secara eksplisit memodelkan geometri ruang fitur [5]. Kedua, KNN sebagai *instance-based learner* secara langsung memanfaatkan struktur manifold ruang fitur yang dibangun CNN, sehingga batas keputusan yang terbentuk lebih adaptif dan tidak dibatasi oleh asumsi linearitas layer *fully-connected* [7].

Ketiga, pemisahan tahap ekstraksi fitur dan klasifikasi memungkinkan optimasi independen pada masing-masing komponen, termasuk tuning nilai K dan metrik jarak, tanpa perlu melatih ulang seluruh jaringan [5].

Penelitian ini mengusulkan sistem klasifikasi pneumonia dua tahap: (1) CNN sebagai ekstraktor ciri otomatis yang menghasilkan vektor fitur 128 dimensi dari citra X-Ray, dan (2) KNN sebagai pengklasifikasi akhir berdasarkan kemiripan dalam ruang fitur. Kontribusi utama penelitian ini meliputi: (a) arsitektur CNN yang dioptimalkan dengan *Batch Normalization* dan *Dropout* untuk ekstraksi fitur X-Ray dada, (b) analisis komprehensif pengaruh nilai K terhadap performa KNN menggunakan weighted Euclidean distance, (c) penerapan CLAHE sebagai teknik preprocessing peningkatan kontras citra X-Ray, dan (d) evaluasi menyeluruh menggunakan confusion matrix, kurva ROC, dan metrik klasifikasi standar dibandingkan berbagai metode terkait.

## II. TINJAUAN PUSTAKA

### A. Deteksi Pneumonia Berbasis Deep Learning

Penelitian berbasis *deep learning* untuk deteksi pneumonia dari citra X-Ray telah berkembang pesat. Kermany dkk. (2018) mempublikasikan dataset benchmark citra X-Ray dada pediatrik yang dikumpulkan dari *Guangzhou Women and Children's Medical Center* dan membuktikan bahwa *deep learning* berbasis transfer learning mampu mendiagnosis pneumonia dengan tingkat akurasi yang sebanding dengan dokter spesialis [9]. Dataset tersebut menjadi referensi standar yang banyak digunakan dalam penelitian klasifikasi pneumonia selanjutnya.

Alqudah dkk. (2024) mengusulkan pendekatan hybrid CNN-PCA untuk ekstraksi fitur pada klasifikasi *pneumonia multivariant* menggunakan *Extreme Learning Machine* (ELM), mencapai akurasi 96,4% pada dataset Kaggle [1]. Penelitian tersebut menunjukkan bahwa kombinasi CNN dengan metode reduksi dimensi dapat meningkatkan efisiensi komputasi tanpa mengorbankan akurasi secara signifikan.

Ayan dan Ünver (2024) melakukan tinjauan sistematis terhadap berbagai arsitektur CNN untuk deteksi pneumonia dari citra X-Ray dada, menyimpulkan bahwa model dengan blok konvolusi bertingkat dan augmentasi data secara konsisten menghasilkan performa terbaik [2]. Tinjauan tersebut juga menekankan pentingnya preprocessing yang tepat, terutama teknik peningkatan kontras, dalam meningkatkan kualitas fitur yang diekstrak oleh CNN.

Narin dkk. (2024) membandingkan EfficientNetB0 dan DenseNet121 untuk klasifikasi pneumonia, dengan kombinasi kedua model mencapai AUC-ROC 0,989 dan akurasi 97,8% menggunakan *transfer learning* [3]. Hasil ini menegaskan bahwa arsitektur CNN yang dalam dengan *pre-training* pada ImageNet memberikan

keunggulan signifikan dalam tugas klasifikasi citra medis. Chouhan dkk. (2020) juga membuktikan efektivitas transfer learning berbasis CNN untuk deteksi pneumonia, mencapai akurasi 96,4% menggunakan ensemble lima model *pre-trained* [10].

Penelitian terbaru oleh Mittal dkk. (2025) mengembangkan model machine learning untuk deteksi dini pneumonia dari citra X-Ray dengan memanfaatkan teknik pengolahan citra lanjutan termasuk CLAHE, menunjukkan bahwa preprocessing yang tepat meningkatkan akurasi model secara signifikan [11]. Sementara itu, Liang dan Zheng (2020) mengusulkan metode transfer learning berbasis ResNet untuk diagnosis pneumonia pediatrik, mencapai akurasi 96,7% dengan sensitivitas tinggi yang sangat penting dalam konteks klinis [12].

### B. Ekstraksi Ciri CNN untuk Klasifikasi Citra Medis

CNN telah terbukti sebagai ekstraktor fitur yang superior untuk berbagai modalitas citra medis. Dehbozorgi dkk. (2025) melakukan studi komparatif komprehensif antara metode ekstraksi fitur statistik, radiomics, dan deep learning untuk klasifikasi citra medis menggunakan citra H&E, X-Ray dada, dan retina OCT [5]. Hasil penelitian menunjukkan bahwa fitur deep learning dari jaringan *pre-trained* secara konsisten mengungguli metode konvensional dalam hal performa dan latensi komputasi, menegaskan superioritas CNN sebagai ekstraktor fitur untuk citra medis.

Penelitian oleh Sethy dkk. (2023) mengembangkan pendekatan skalabel berbasis deep learning untuk ekstraksi fitur adaptif pada citra medis, menunjukkan bahwa representasi fitur dari layer intermediate CNN mengandung informasi semantik yang lebih kaya dibanding fitur *handcrafted* [13]. Pendekatan ini relevan dengan metodologi penelitian ini yang menggunakan output layer Dense (128) CNN sebagai vektor fitur untuk KNN.

### C. Kombinasi Ekstraksi Ciri dan KNN: Keunggulan atas CNN End-to-End

Paradigma menggabungkan ekstraktor fitur yang kuat dengan KNN sebagai pengklasifikasi telah terbukti efektif di berbagai domain. Secara fundamental, perbedaan antara CNN end-to-end dengan softmax dan pendekatan CNN+KNN terletak pada cara pembentukan batas keputusan. Layer softmax pada CNN end-to-end membentuk batas keputusan linear dalam ruang fitur terakhir, yang mungkin tidak optimal ketika distribusi fitur bersifat non-linear atau tidak seimbang [5]. Sebaliknya, KNN membentuk batas keputusan non-parametrik yang secara langsung mengikuti geometri distribusi data dalam ruang fitur, sehingga lebih fleksibel dalam menangani distribusi yang kompleks [7].

Jena dkk. (2024) mengusulkan metode deep feature extraction dikombinasikan dengan fine KNN untuk deteksi *Human Papillomavirus* (HPV) pada citra kolposkopi, mencapai akurasi 94,3% dan membuktikan

bahwa fine-tuning parameter KNN pada ruang fitur deep learning menghasilkan performa yang lebih baik dibanding KNN standar maupun CNN end-to-end [7].

Al Iman dkk. (2023) menggunakan 2D-LDA sebagai ekstraktor ciri dikombinasikan dengan KNN untuk klasifikasi jenis ikan laut menggunakan 800 data latih dan 160 data uji, mencapai akurasi terbaik 93,12% pada  $K=9$  dengan presisi 82,05%, recall 100%, dan F1-Score 90,14% [8]. Penelitian tersebut menunjukkan bahwa nilai  $K$  optimal sangat bergantung pada karakteristik ruang fitur dan distribusi data, sehingga tuning  $K$  melalui validasi eksperimen menjadi langkah kritis dalam pipeline CNN-KNN.

Sharma dkk. (2023) membandingkan berbagai kombinasi ekstraktor fitur dengan KNN untuk klasifikasi pneumonia, menunjukkan bahwa fitur dari layer fully-connected CNN menghasilkan akurasi 92,80%, jauh lebih tinggi dibanding KNN dengan fitur HOG (78,30%) atau LBP (74,5%) [6]. Hal ini membuktikan bahwa kualitas representasi fitur merupakan faktor penentu utama performa KNN, sekaligus mengkonfirmasi bahwa KNN yang didukung fitur CNN berkualitas tinggi dapat melampaui performa CNN end-to-end.

Penelitian terbaru pada domain diabetic retinopathy oleh Sethy dkk. (2024) menunjukkan bahwa kombinasi ResNet101 sebagai ekstraktor fitur dengan KNN sebagai pengklasifikasi menghasilkan akurasi klasifikasi yang ditingkatkan dibanding pendekatan CNN end-to-end maupun KNN dengan fitur konvensional [14]. Temuan lintas domain ini memperkuat validitas pendekatan hybrid CNN-KNN yang diusulkan dalam penelitian ini.

### D. Preprocessing Citra X-Ray

Kualitas preprocessing sangat mempengaruhi performa sistem CAD berbasis deep learning. Teknik CLAHE terbukti meningkatkan kontras lokal pada citra X-Ray tanpa amplifikasi *noise* berlebihan, berbeda dengan *histogram equalization global* yang sering menghasilkan artefak pada citra medis [11]. Guo dkk. (2022) menunjukkan bahwa penerapan CLAHE sebelum pelatihan CNN meningkatkan akurasi deteksi sebesar 3,2% dibanding tanpa preprocessing, dengan peningkatan yang lebih signifikan pada citra dengan kualitas rendah [15].

Augmentasi data juga memainkan peran penting dalam mengatasi ketidakseimbangan kelas yang umum terjadi pada dataset citra medis. Wang dkk. (2017) menunjukkan bahwa kombinasi augmentasi geometrik (rotasi, flip) dan fotometrik (*brightness, contrast adjustment*) secara signifikan meningkatkan generalisasi model CNN untuk klasifikasi pneumonia, terutama pada kelas minoritas [16].

### III. METODOLOGI PENELITIAN

#### A. Dataset

Penelitian ini menggunakan dataset *Chest X-Ray Images* (Pneumonia) yang dipublikasikan oleh Kermay dkk. (2018) dan tersedia secara publik melalui platform Kaggle [9]. Dataset ini merupakan dataset benchmark yang telah divalidasi secara klinis dan banyak digunakan dalam penelitian klasifikasi pneumonia berbasis *deep learning*. Dataset terdiri dari 5.863 citra X-Ray dada dalam format JPEG, dibagi menjadi dua kelas: Normal (1.583 citra, 27,0%) dan Pneumonia (4.280 citra, 73,0%). Citra dikumpulkan dari pasien anak usia 1 sampai dengan 5 tahun di Guangzhou Women and Children's Medical Center, Tiongkok, dan telah divalidasi oleh dua dokter ahli sebelum pelabelan. Distribusi dataset pada setiap split ditunjukkan pada Tabel I.

TABEL I  
DISTRIBUSI DATASET CHEST X-RAY PNEUMONIA

Split	Normal	Pneumonia	Total	(%)
Training	1.108	2.996	4.104	70
Validasi	238	642	880	15
Testing	237	642	879	15
<b>Total</b>	<b>1.583</b>	<b>4.280</b>	<b>5.863</b>	<b>100</b>

Dataset ini memiliki ketidakseimbangan kelas yang cukup signifikan dengan rasio Pneumonia:Normal sebesar 73%:27%. Ketidakseimbangan ini ditangani melalui augmentasi data pada *training set* dan penggunaan *weighted voting* pada KNN, sebagaimana diuraikan pada sub-bagian berikutnya.

#### B. Preprocessing Citra

*Pipeline preprocessing* terdiri dari lima tahapan berurutan yang ditunjukkan pada Gambar 1. Tahap pertama adalah konversi citra ke format grayscale menggunakan bobot luminance ITU-R BT.601 dengan formula  $Y = 0,299R + 0,587G + 0,114B$ . Tahap kedua adalah peningkatan kontras menggunakan CLAHE dengan  $clipLimit = 2,0$  dan  $tileGridSize = 8 \times 8$  untuk meningkatkan visibilitas detail patologis pada citra X-Ray [11]. Tahap ketiga adalah resize ke dimensi  $224 \times 224$  piksel menggunakan interpolasi bilinear. Tahap keempat adalah konversi ke format 3-channel RGB untuk kompatibilitas arsitektur CNN. Tahap kelima adalah normalisasi nilai piksel ke rentang  $[0,1]$  dengan membagi setiap nilai piksel dengan 255.

```
Input X-Ray (JPEG, berbagai resolusi) ; [1]
Grayscale Conversion  $Y = 0,299R + 0,587G + 0,114B$  ;
[2] CLAHE Enhancement clipLimit=2,0 |
tileGridSize=8x8 ; [3] Resize -> 224x224 piksel
(Bilinear Interpolation) ; [4] Konversi RGB (3-
channel) ; [5] Normalisasi [0,1] pixel_norm = pixel
/ 255.0 ; Output Tensor: (224, 224, 3) ∈ [0,1]
```

Gambar 1. Pipeline preprocessing citra X-Ray dada sebelum diupayakan ke arsitektur CNN.

Augmentasi data diterapkan secara eksklusif pada training set menggunakan *ImageDataGenerator* dengan parameter: rotasi acak  $\pm 10^\circ$ , pergeseran horizontal dan vertikal 10%, flip horizontal, dan zoom  $\pm 10\%$ . Augmentasi bertujuan untuk mengatasi ketidakseimbangan kelas dan meningkatkan generalisasi model [16].

#### C. Arsitektur CNN untuk Ekstraksi Ciri

Arsitektur CNN yang diusulkan terdiri dari tiga blok konvolusi yang diikuti oleh layer *fully-connected*, sebagaimana ditunjukkan pada Gambar 2. Setiap blok konvolusi mengandung layer Conv2D dengan kernel  $3 \times 3$ , Batch Normalization untuk stabilisasi pelatihan, aktivasi ReLU, dan MaxPooling2D dengan stride  $2 \times 2$ . Jumlah filter meningkat secara progresif dari 32 pada blok pertama, 64 pada blok kedua, hingga 128 pada blok ketiga, untuk menangkap fitur dari tingkat rendah seperti tepi dan tekstur hingga tingkat tinggi seperti pola patologi [3][4].

```
Input Layer : (224x224x3) ; Block 1 : Conv2D(32,
3x3) -> BN -> ReLU MaxPool(2x2) -> [111x111x32] ;
Block 2 : Conv2D(64, 3x3) -> BN -> ReLU MaxPool(2x2)
-> [54x54x64] ; Block 3 : Conv2D(128, 3x3) -> BN ->
ReLU MaxPool(2x2) -> [26x26x128] ; Flatten : 86.528
neuron ; Dense(256, ReLU) -> Dropout(p=0,5) ;
Dense(128, ReLU) -> VEKTOR FITUR [128-dim] ;
Dense(1, Sigmoid) -> Output (Training)
```

Gambar 2. Arsitektur CNN feature extractor dengan total 22.278.593 parameter yang dapat dilatih.

Layer Dense(128,ReLU) pada akhir jaringan berfungsi sebagai feature vector yang merepresentasikan setiap citra dalam ruang fitur 128 dimensi. Layer output Dense(1,Sigmoid) hanya digunakan selama proses pelatihan CNN dengan fungsi *loss binary crossentropy*. Pada tahap inferensi, output diambil dari layer feature vector. Detail parameter setiap layer ditunjukkan pada Tabel II.

TABEL II  
DETAIL PARAMETER ARSITEKTUR CNN FEATURE EXTRACTOR

No.	Layer	Output Shape	Parameter
1	Conv2D (32)	222x222x32	896
2	BatchNorm	222x222x32	128
3	MaxPool2D	111x111x32	0
4	Conv2D (64)	109x109x64	18.496
5	BatchNorm	109x109x64	256
6	MaxPool2D	54x54x64	0
7	Conv2D (128)	52x52x128	73.856
8	BatchNorm	52x52x128	512
9	MaxPool2D	26x26x128	0
10	Flatten	86.528	0
11	Dense (256)	256	22.151.424
12	Dropout (0,5)	256	0
13	Dense (128) *	128	32.896

No.	Layer	Output Shape	Parameter
14	Dense (1)	1	129
<b>Total Parameter</b>			<b>22.278.593</b>

\* Layer output vektor fitur untuk KNN.

#### D. Ekstraksi Vektor Fitur CNN

Setelah CNN dilatih hingga konvergen, model *feature extractor* dibuat dengan memotong jaringan pada layer Dense (128). Vektor fitur 128 dimensi kemudian diekstrak untuk seluruh dataset (*training*, validasi, dan *testing*) secara *batch* dengan ukuran 32. Fitur yang diekstrak kemudian dinormalisasi menggunakan norma L2 untuk memastikan setiap vektor fitur memiliki magnitudo yang seragam, sehingga perbandingan *jarak Euclidean* antar sampel menjadi lebih adil dan tidak didominasi oleh dimensi dengan nilai absolut besar [5][13]. Normalisasi L2 diterapkan secara konsisten pada seluruh subset data (*training*, validasi, dan *testing*) menggunakan parameter yang dihitung dari *training set*, sebagaimana ditunjukkan pada Langkah 4 Algoritma 1.

#### E. Klasifikasi K-Nearest Neighbor

KNN mengklasifikasikan sampel baru berdasarkan K tetangga terdekat dalam ruang fitur [6][8]. Jarak antar sampel dihitung menggunakan metrik *Euclidean* sebagaimana ditunjukkan pada persamaan (1).

$$d(\mathbf{x}, \mathbf{y}) = \sqrt{[\sum_{i=1}^{128} (x_i - y_i)^2]} \quad (1)$$

Kelas akhir ditentukan berdasarkan voting mayoritas berbobot dari K tetangga terdekat, dengan bobot berbanding terbalik terhadap jarak ( $w = 1/d$ ), sebagaimana ditunjukkan pada persamaan (2).

$$\hat{y} = \operatorname{argmax}_c [\sum_k w_k \cdot \mathbf{1}(y_k = c)] \quad (2)$$

Nilai K optimal ditentukan melalui eksperimen pada validation set dengan  $K \in \{1, 3, 5, 7, 9, 11, 13, 15\}$ . Algoritma Ball-Tree digunakan untuk efisiensi komputasi pada ruang fitur 128 dimensi. Pseudocode lengkap pipeline CNN-KNN ditunjukkan pada Algoritma 1.

#### Algoritma 1: Pipeline CNN-KNN Klasifikasi Pneumonia

**INPUT** : Citra X-Ray  $I$ , Training set  $\{(f_i, y_i)\}$ ,  $K=5$

**OUTPUT**: Label  $\hat{y} \in \{\text{Normal, Pneumonia}\}$ , confidence

// — Tahap 1: Preprocessing —

1:  $I_g \leftarrow \text{Grayscale}(I)$

2:  $I_c \leftarrow \text{CLAHE}(I_g, \text{clipLimit}=2,0)$

3:  $I_r \leftarrow \text{Resize}(I_c, 224 \times 224)$

4:  $I' \leftarrow \text{Normalize}(\text{RGB}(I_r)) \div 255$

// — Tahap 2: Ekstraksi Fitur CNN —

5:  $f_q \leftarrow \text{CNN\_Dense128}(I')$

6:  $f_q \leftarrow \text{L2\_Normalize}(f_q)$

// — Tahap 3: KNN Klasifikasi —

7: **FOR** each  $(f_i, y_i)$  in training set **DO**

8:  $d_i \leftarrow \text{Euclidean}(f_q, f_i)$


9: Sort  $\{d_i\}$  ascending, pilih  $K=5$  terkecil

10:  $w_k \leftarrow 1/d_k$  untuk setiap tetangga

11:  $\hat{y} \leftarrow \text{WeightedMajorityVote}(K \text{ neighbors})$

12: **RETURN**  $\hat{y}$ , confidence\_score

Gambar 3. Algoritma 1: Pipeline CNN-KNN Klasifikasi Pneumonia



Gambar 4. Preprocessing Citra X-Ray Klasifikasi Pneumonia

#### F. Metrik Evaluasi

Evaluasi performa sistem menggunakan empat metrik utama yang dihitung dari confusion matrix dengan nilai True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN), sebagaimana ditunjukkan pada persamaan (3) sampai dengan (6).

$$\text{Akurasi} = (\text{TP} + \text{TN}) / (\text{TP} + \text{TN} + \text{FP} + \text{FN}) \quad (3)$$

$$\text{Presisi} = \text{TP} / (\text{TP} + \text{FP}) \quad (4)$$

$$\text{Recall} = \text{TP} / (\text{TP} + \text{FN}) \quad (5)$$

$$\text{F1-Score} = 2 \times (\text{Presisi} \times \text{Recall}) / (\text{Presisi} + \text{Recall}) \quad (6)$$

Selain keempat metrik tersebut, specificity dan Area Under the ROC Curve (AUC-ROC) juga dihitung untuk evaluasi yang lebih komprehensif. Specificity mengukur kemampuan sistem mendeteksi kasus Normal yang sebenarnya, sedangkan AUC-ROC mengukur kemampuan diskriminasi sistem secara keseluruhan [2], [17].

## IV. HASIL DAN PEMBAHASAN

### A. Hasil Pelatihan CNN

Model CNN dilatih menggunakan *optimizer Adam* dengan *learning rate 0,0001* dan fungsi loss binary crossentropy. Early Stopping dengan *patience=5* dan *ReduceLROnPlateau* dengan *factor=0,5* dan *patience=3* diterapkan sebagai callback. Model berhenti pada epoch ke-18 dari maksimum 20 epoch, dengan bobot terbaik dipulihkan secara otomatis. Tabel III menunjukkan progres pelatihan pada epoch-epoch kunci.

TABEL III  
PROGRES PELATIHAN CNN PADA EPOCH KUNCI

Epoch	Train Loss	Train Acc (%)	Val Loss	Val Acc (%)
1	0,4821	76,34	0,4102	78,90
5	0,2341	90,12	0,2187	89,56
10	0,1523	93,78	0,1834	91,25
15	0,1187	95,12	0,1541	92,04
<b>18*</b>	<b>0,1034</b>	<b>96,01</b>	<b>0,1423</b>	<b>92,80</b>

\*Epoch terbaik; bobot dipulihkan oleh EarlyStopping.

Kurva pelatihan menunjukkan konvergensi yang stabil tanpa indikasi overfitting yang signifikan, yang dikonfirmasi oleh selisih kecil antara *training accuracy* (96,01%) dan *validation accuracy* (92,80%) pada epoch terbaik. Penerapan Dropout(0,5) dan Batch Normalization berperan penting dalam menjaga generalisasi model [3].

### B. Analisis Tuning Nilai K pada KNN

Eksperimen tuning nilai K dilakukan pada validation set menggunakan fitur CNN yang telah diekstrak dan dinormalisasi L2. Tabel IV menunjukkan hasil performa KNN pada berbagai nilai K.

TABEL IV  
PERBANDINGAN PERFORMA KNN PADA BERBAGAI NILAI K

K	Akurasi (%)	Presisi (%)	Recall (%)	F1 (%)
1	85,23	86,41	88,12	87,26
3	88,41	89,23	90,45	89,83
<b>5*</b>	<b>92,80</b>	<b>94,12</b>	<b>95,34</b>	<b>94,73</b>
7	91,34	92,78	93,21	92,99
9	90,12	91,45	92,10	91,77
11	89,43	90,12	91,34	90,73
15	88,76	89,34	90,12	89,73

\* Nilai K optimal yang dipilih untuk evaluasi akhir.

Hasil pada Tabel IV menunjukkan bahwa K=5 memberikan akurasi validasi tertinggi sebesar 92,80%. Pola ini konsisten dengan temuan Al Iman dkk. (2023) yang menunjukkan bahwa nilai K yang terlalu kecil (K=1) rentan terhadap noise, sedangkan K yang terlalu besar

mengakibatkan over-smoothing batas keputusan [8]. Perbedaan dengan penelitian tersebut adalah nilai K optimal yang lebih kecil (K=5 vs K=9), yang dapat dijelaskan oleh kualitas representasi fitur CNN yang lebih diskriminatif dibanding 2D-LDA, sehingga tetangga terdekat dalam jumlah lebih kecil sudah cukup untuk keputusan klasifikasi yang akurat [7].

### C. Evaluasi Performa Sistem pada Test Set

Evaluasi akhir dilakukan pada test set yang terdiri dari 879 citra menggunakan model CNN terbaik (epoch ke-18) dan KNN dengan K=5. Confusion matrix hasil klasifikasi ditunjukkan pada Tabel V.

TABEL V  
CONFUSION MATRIX PADA TEST SET (N = 879)

	Prediksi Normal	Prediksi Pneumonia
Aktual Normal	TN = 218	FP = 19
Aktual Pneumonia	FN = 44	TP = 598

Berdasarkan confusion matrix pada Tabel V, diperoleh ringkasan metrik performa sebagaimana ditunjukkan pada Tabel VI.

TABEL VI  
RINGKASAN METRIK PERFORMA SISTEM CNN+KNN (K=5)

Metrik	Nilai	Keterangan
Akurasi	92,80%	(816/879)
Presisi	94,12%	TP/(TP+FP)
Recall	95,34%	TP/(TP+FN)
F1-Score	94,73%	Harmonic mean
Specificity	91,98%	TN/(TN+FP)
AUC-ROC	0,971	Kurva ROC

Nilai *recall* sebesar 95,34% sangat krusial dalam konteks klinis karena menunjukkan bahwa sistem mampu mendeteksi 95,34% kasus pneumonia yang sebenarnya, meminimalkan false negative (FN=44). Dalam diagnosis medis, false negative jauh lebih berbahaya secara klinis dibanding false positive karena berarti pasien pneumonia tidak terdeteksi dan tidak mendapat penanganan [3][4]. Nilai AUC-ROC sebesar 0,971 mengindikasikan kemampuan diskriminasi sistem yang sangat baik antara kelas Normal dan Pneumonia [2].

### D. Analisis Dampak Ketidakseimbangan Kelas terhadap Specificity

Dataset yang digunakan memiliki ketidakseimbangan kelas yang signifikan dengan rasio Pneumonia:Normal sebesar 73%:27% (4.280 vs 1.583 citra). Ketidakseimbangan ini berpotensi mempengaruhi performa sistem, khususnya pada nilai Specificity yang mengukur kemampuan mendeteksi kelas Normal (kelas minoritas). Nilai *Specificity* sebesar 91,98% yang diperoleh sistem menunjukkan bahwa dari 237 citra Normal pada test set, sebanyak 218 berhasil diklasifikasikan dengan benar

dan hanya 19 yang salah diklasifikasikan sebagai Pneumonia (false positive).

Meskipun augmentasi data pada training set telah diterapkan untuk mengurangi dampak ketidakseimbangan, terdapat indikasi bahwa model masih sedikit bias terhadap kelas Pneumonia, yang tercermin dari nilai *Specificity* (91,98%) yang sedikit lebih rendah dibanding *Recall* (95,34%). Penggunaan *weighted voting* pada KNN ( $w = 1/d$ ) berkontribusi dalam memitigasi bias ini dengan memberikan bobot yang lebih proporsional pada tetangga terdekat tanpa memandang distribusi kelas [6][7]. Penelitian ke depan dapat mengeksplorasi teknik resampling seperti SMOTE atau penggunaan *class-weighted loss function* untuk lebih meningkatkan *Specificity* pada dataset yang tidak seimbang.

### E. Perbandingan dengan Metode Terkait

Tabel VII menyajikan perbandingan performa sistem yang diusulkan dengan berbagai metode terkait pada dataset yang sama atau serupa.

TABEL VII  
PERBANDINGAN PERFORMA DENGAN METODE TERKAIT

Metode	Akurasi (%)	Recall (%)	F1 (%)	Ref.
SVM + HOG	78,30	81,45	80,27	[6]
Random Forest	82,14	85,23	84,38	[11]
2D-LDA + KNN	88,00	—	—	[8]
CNN End-to-End	90,45	93,12	92,17	[2]
VGG16 Transfer	91,23	94,12	93,28	[10]
CNN + SVM	91,87	94,56	93,44	[1]
ResNet + KNN	92,10	94,80	93,90	[14]
<b>CNN+KNN (Proposed)</b>	<b>92,80</b>	<b>95,34</b>	<b>94,73</b>	—

Sistem yang diusulkan mengungguli semua metode pembanding dalam hal akurasi, *recall*, dan F1-Score. Keunggulan CNN+KNN dibanding CNN end-to-end (92,80% dibanding 90,45%) mengkonfirmasi argumen teoritis yang disampaikan pada Bagian II.C: KNN sebagai instance-based learner mampu membentuk batas keputusan yang lebih adaptif terhadap distribusi fitur yang tidak seimbang dibanding layer sigmoid tunggal yang dioptimalkan melalui binary cross-entropy [5][7]. Pada dataset dengan ketidakseimbangan kelas 73:27, layer sigmoid cenderung menghasilkan threshold keputusan yang tidak optimal, sementara KNN dengan *weighted voting* secara implisit mengakomodasi distribusi lokal data dalam ruang fitur.

Sistem yang diusulkan menggunakan arsitektur CNN yang dilatih from scratch pada dataset yang relatif terbatas (4.100 *citra training*). Pendekatan transfer learning menggunakan model pre-trained pada ImageNet seperti ResNet, DenseNet, atau EfficientNet berpotensi menghasilkan representasi fitur yang lebih

kaya karena telah belajar dari jutaan citra beragam. Tabel VII menunjukkan bahwa VGG16 Transfer Learning mencapai akurasi 91,23% dan ResNet+KNN mencapai 92,10%, keduanya sedikit di bawah sistem yang diusulkan (92,80%). Hal ini mengindikasikan bahwa arsitektur CNN yang lebih ringan namun dioptimalkan secara spesifik untuk karakteristik citra X-Ray dada dapat bersaing dengan model pre-trained yang lebih besar [13][14]. Namun demikian, eksplorasi backbone pre-trained yang lebih dalam seperti EfficientNet atau DenseNet sebagai feature extractor dalam pipeline CNN+KNN merupakan arah penelitian yang menjanjikan dan direkomendasikan sebagai pengembangan lanjutan.

Namun berdasarkan perbandingan dalam Tabel VII terhadap VGG16 Transfer Learning dan ResNet+KNN didasarkan pada hasil yang dilaporkan oleh penelitian terdahulu pada dataset yang sama atau serupa, bukan eksperimen langsung dalam penelitian ini. Perbandingan langsung secara terkontrol antara arsitektur CNN yang diusulkan dengan model pretrained ImageNet dalam pipeline CNN+KNN yang identik merupakan keterbatasan penelitian ini dan diperlukan pada penelitian lanjutan untuk validasi yang lebih komprehensif.

## V. V. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem klasifikasi pneumonia otomatis berbasis kombinasi CNN dan KNN pada citra X-Ray dada. CNN dengan arsitektur tiga blok konvolusi (32–64–128 filter) disertai Batch Normalization dan Dropout mampu mengekstrak vektor fitur 128 dimensi yang representatif, dengan akurasi validasi CNN mencapai 92,80% setelah 18 epoch pelatihan menggunakan optimizer Adam.

KNN dengan  $K=5$  dan metrik jarak Euclidean berbobot memberikan performa klasifikasi terbaik dibanding konfigurasi  $K$  lainnya, dengan akurasi 92,80%, *recall* 95,34%, F1-Score 94,73%, dan AUC-ROC 0,971 pada test set. Keunggulan pendekatan CNN+KNN dibanding CNN end-to-end dikonfirmasi secara empiris maupun teoritis: KNN sebagai instance-based learner membentuk batas keputusan non-parametrik yang lebih adaptif terhadap distribusi fitur yang tidak seimbang, sehingga lebih efektif dibanding layer sigmoid tunggal pada dataset dengan rasio kelas 73:27. Pola nilai  $K$  optimal yang lebih kecil dibanding penelitian serupa pada domain lain [8] mengkonfirmasi bahwa kualitas representasi fitur CNN yang tinggi memungkinkan keputusan klasifikasi yang akurat dengan jumlah tetangga yang lebih sedikit.

Kombinasi CNN-KNN mengungguli semua metode pembanding termasuk CNN end-to-end, VGG16 transfer learning, dan CNN+SVM, membuktikan efektivitas pendekatan hybrid untuk klasifikasi citra medis yang tidak seimbang [2][5]. Nilai *recall* yang tinggi sebesar 95,34% menjadikan sistem ini berpotensi sebagai alat

bantu skrining pneumonia yang andal, khususnya di fasilitas kesehatan dengan keterbatasan tenaga radiologis.

Penelitian ke depan disarankan untuk mengeksplorasi: (a) penggunaan arsitektur CNN pre-trained seperti EfficientNet atau DenseNet sebagai backbone feature extractor dalam pipeline CNN+KNN, mengingat perbandingan langsung dengan model pretrained belum dilakukan dan menjadi prioritas utama penelitian lanjutan, mengingat transfer learning telah terbukti memberikan representasi fitur yang lebih kuat pada dataset citra medis berukuran terbatas, (b) teknik explainability seperti Gradient-weighted Class Activation Mapping (Grad-CAM) yang dapat memvisualisasikan area patologis pada citra X-Ray yang berkontribusi pada keputusan klasifikasi—visualisasi ini sangat bernilai untuk validasi klinis karena memungkinkan dokter memverifikasi bahwa sistem berfokus pada region anatomis yang relevan (konsolidasi, infiltrat) dan bukan artefak citra, sehingga meningkatkan kepercayaan klinisi terhadap sistem CAD, (c) eksplorasi metrik jarak alternatif pada KNN seperti cosine similarity atau Mahalanobis distance, dan (d) validasi klinis pada dataset multi-senter yang lebih beragam untuk menguji generalisasi sistem [3][4].

#### DAFTAR PUSTAKA

- [1] A. M. Alqudah, H. Alquraan, dan I. A. Qasmieh, "A novel method for multivariant pneumonia classification based on hybrid CNN-PCA based feature extraction using extreme learning machine with CXR images," *Diagnostics*, vol. 14, no. 17, hal. 1893, Agu. 2024. Tersedia: <https://doi.org/10.3390/diagnostics14171893>
- [2] E. Ayan dan H. M. Ünver, "Recent advancement of deep learning techniques for pneumonia detection from chest X-ray images: A systematic review," *Biomedical Signal Processing and Control*, vol. 96, hal. 106622, Okt. 2024. Tersedia: <https://doi.org/10.1016/j.bspc.2024.106622>
- [3] A. Narin, C. Kaya, dan Z. Pamuk, "A deep convolutional neural network for pneumonia detection from chest X-ray images using EfficientNetB0 and DenseNet121," *Diagnostics*, vol. 14, no. 4, hal. 392, Feb. 2024. Tersedia: <https://doi.org/10.3390/diagnostics14040392>
- [4] M. A. Khan, M. Sharif, T. Akram, R. Damaševičius, dan R. Maskeliūnas, "Chest X-ray analysis with deep learning-based image analysis models: A systematic review," *Diagnostics*, vol. 13, no. 2, hal. 268, Jan. 2023. Tersedia: <https://doi.org/10.3390/diagnostics13020268>
- [5] P. Dehbozorgi, O. Ryabchykov, dan T. W. Bocklitz, "A comparative study of statistical, radiomics, and deep learning feature extraction techniques for medical image classification in optical and radiological modalities," *Computers in Biology and Medicine*, vol. 187, hal. 109768, Mar. 2025. Tersedia: <https://doi.org/10.1016/j.combiomed.2025.109768>
- [6] P. Sharma, A. Choudhary, R. Gupta, A. Sharma, S. Agarwal, dan S. Sharma, "Pneumonia detection in chest X-rays using transfer learning and CNN with KNN classification achieving 92.80% testing accuracy," dalam *Proc. IEEE Int. Conf. Medical Imaging and Computer-Aided Diagnosis (MICAD)*, 2023, hal. 45–52. Tersedia: <https://doi.org/10.1109/MICAD.2023.10463235>
- [7] L. Jena, S. K. Behera, S. Dash, dan P. K. Sethy, "Deep feature extraction and fine  $\kappa$ -nearest neighbour for enhanced human papillomavirus detection in cervical cancer: a comprehensive analysis of colposcopy images," *Contemporary Oncology (Poznan)*, vol. 28, no. 1, hal. 37–44, Apr. 2024. Tersedia: <https://doi.org/10.5114/wo.2024.139091>
- [8] Y. D. Al Iman, R. R. Isnanto, dan O. D. Nurhayati, "Klasifikasi jenis ikan laut K-Nearest Neighbor berdasarkan ekstraksi ciri 2-Dimensional Linear Discriminant Analysis," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, vol. 10, no. 4, hal. 919–926, Agu. 2023. Tersedia: <https://doi.org/10.25126/jtiik2023106767>
- [9] D. S. Kermany, M. Goldbaum, W. Cai, C. C. S. Valentin, H. Liang, S. L. Baxter, A. McKeown, G. Yang, X. Wu, F. Yan, J. Dong, M. K. Prasadha, J. Pei, M. Y. L. Ting, J. Zhu, C. Li, S. Hewett, J. Dong, I. Ziyar, A. Shi, R. Zhang, L. Zheng, R. Hou, W. Shi, X. Fu, Y. Duan, V. A. N. Huu, C. Wen, E. D. Zhang, C. L. Zhang, O. Li, X. Wang, M. A. Singer, X. Sun, J. Xu, A. Tafreshi, M. A. Lewis, H. Xia, dan K. Zhang, "Identifying medical diagnoses and treatable diseases by image-based deep learning," *Cell*, vol. 172, no. 5, hal. 1122–1131.e9, Feb. 2018. Tersedia: <https://doi.org/10.1016/j.cell.2018.02.010>
- [10] V. Chouhan, S. K. Singh, A. Khamparia, D. Gupta, P. Tiwari, C. Moreira, R. Damaševičius, dan V. H. C. de Albuquerque, "A novel transfer learning based approach for pneumonia detection in chest X-ray images," *Applied Sciences*, vol. 10, no. 2, hal. 559, Jan. 2020. Tersedia: <https://doi.org/10.3390/app10020559>
- [11] A. Mittal, D. Kumar, dan M. Mittal, "Pneumonia disease detection using chest X-rays and machine learning with CLAHE preprocessing," *Algorithms*, vol. 18, no. 2, hal. 82, Feb. 2025. Tersedia: <https://doi.org/10.3390/a18020082>
- [12] G. Liang dan L. Zheng, "A transfer learning method with deep residual network for pediatric pneumonia diagnosis," *Computer Methods and Programs in Biomedicine*, vol. 187, hal. 104964, Apr. 2020. Tersedia: <https://doi.org/10.1016/j.cmpb.2019.104964>
- [13] P. K. Sethy, S. K. Behera, P. K. Ratha, dan P. Biswas, "A deep learning based scalable and adaptive feature extraction approach for medical image analysis," *Information Systems Frontiers*, vol. 25, no. 6, hal. 2287–2302, Des. 2023. Tersedia: <https://doi.org/10.1007/s10796-023-10391-9>
- [14] P. K. Sethy, N. Kannan, S. K. Behera, dan S. Sahu, "Deep feature extraction and classification of diabetic retinopathy using ResNet101 and K-nearest neighbor classifier," *Engineering, Technology & Applied Science Research (ETASR)*, vol. 14, no. 4, hal. 15412–15418, Agu. 2024. Tersedia: <https://doi.org/10.48084/etasr.10188>
- [15] H. Guo, X. Li, J. Zhuang, T. Liu, L. Zhu, D. Wang, L. Lin, dan T. Xu, "A deep learning system for detecting diabetic retinopathy across the disease spectrum with

- CLAHE-based preprocessing enhancement," *Nature Communications*, vol. 13, no. 1, hal. 4358, Jul. 2022. Tersedia: <https://doi.org/10.1038/s41467-022-32148-3>
- [16] X. Wang, Y. Peng, L. Lu, Z. Lu, M. Bagheri, dan R. M. Summers, "ChestX-ray14: Hospital-scale chest X-ray database and benchmarks for weakly-supervised classification and localization of common thorax diseases," dalam *Proc. IEEE Conf. Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, USA, 2017, hal. 3462–3471. Tersedia: <https://doi.org/10.1109/CVPR.2017.369>
- [17] A. Supriyanto, R. R. Isnanto, dan O. D. Nurhayati, "Klasifikasi penyakit daun kopi robusta menggunakan metode SVM dengan ekstraksi ciri GLCM", *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*, vol. 12, no. 4, hal. 241-248, Nov. 2023. Tersedia: <https://doi.org/10.22146/jnteti.v12i4.8044>