

Analisis Tekstur Berbasis GLCM dan Klasifikasi KNN-SVM untuk Identifikasi Pneumonia pada Citra Rontgen

Nirin Fathonah Hismaya*¹, Nani Sulistianingsih²

^{1,2}Sistem dan Teknologi Informasi, Universitas Muhammadiyah Mataram, Indonesia

¹nirinfathonah@gmail.com, ²nani.sulistianingsih@ummat.ac.id

ABSTRACT

Keywords:

Pneumonia
GLCM
KNN
SVM
Image Classification

Abstract: *Pneumonia is a lung infection that can cause serious complications, so a quick and accurate diagnosis is essential. This study aims to identify pneumonia from chest X-ray images using the Gray-Level Co-Occurrence Matrix (GLCM) feature extraction method and compare the classification performance between Support Vector Machine (SVM) and K-Nearest Neighbour (KNN). The dataset used was obtained from Kaggle and has gone through the preprocessing and extraction stages of texture features using GLCM. Model evaluation is carried out based on accuracy, precision, recall, and F1-score. The results show that SVM has an initial validation accuracy of 89.46% and a testing accuracy of 76.1%. After parameter tuning, the accuracy of the SVM increased to 93.97%, indicating better performance than the KNN, which only achieved 81.61% validation accuracy and 73.72% test accuracy. SVM is also more stable in classifying pneumonia than KNN, which shows weakness in detecting normal categories. Thus, the SVM model with tuning is the best choice in detecting pneumonia based on texture analysis of chest X-ray images.*

Kata Kunci:

Pneumonia
GLCM
KNN
SVM
Klasifikasi Citra

Abstrak: *Pneumonia merupakan penyakit infeksi paru yang dapat menyebabkan komplikasi serius, sehingga diagnosis yang cepat dan akurat sangat diperlukan. Penelitian ini bertujuan untuk mengidentifikasi pneumonia dari citra rontgen dada menggunakan metode ekstraksi fitur Gray-Level Co-Occurrence Matrix (GLCM) dan membandingkan performa klasifikasi antara Support Vector Machine (SVM) dan K-Nearest Neighbors (KNN). Dataset yang digunakan diperoleh dari Kaggle dan telah melalui tahap preprocessing serta ekstraksi fitur tekstur menggunakan GLCM. Evaluasi model dilakukan berdasarkan akurasi, precision, recall, dan F1-score. Hasil penelitian menunjukkan bahwa SVM memiliki akurasi validasi awal sebesar 89,46% dan akurasi pengujian sebesar 76,1%. Setelah tuning parameter, akurasi SVM meningkat hingga 93,97%, menunjukkan performa yang lebih baik dibandingkan KNN, yang hanya mencapai akurasi validasi 81,61% dan akurasi pengujian 73,72%. SVM juga lebih stabil dalam mengklasifikasikan pneumonia dibandingkan KNN, yang menunjukkan kelemahan dalam mendeteksi kategori normal. demikian, model SVM dengan tuning menjadi pilihan terbaik dalam mendeteksi pneumonia berbasis analisis tekstur citra rontgen dada.*

Article History:

Received : 25-02-2025

Accepted : 29-03-2025



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

A. LATAR BELAKANG

Pneumonia merupakan salah satu penyakit infeksi paru yang dapat menyebabkan komplikasi serius, terutama bagi kelompok rentan seperti anak-anak dan lansia. Diagnosis yang cepat dan akurat menjadi sangat penting untuk menurunkan angka mortalitas dan morbiditas akibat penyakit ini (Baig et al., 2024). Kemajuan teknologi dalam bidang pengolahan citra medis dan kecerdasan buatan, pendekatan berbasis analisis tekstur dan pembelajaran mesin menjadi alternatif yang menjanjikan dalam meningkatkan akurasi deteksi *pneumonia*. *Gray-Level Co-Occurrence Matrix*

(GLCM) telah terbukti sebagai metode yang efektif dalam ekstraksi fitur tekstur dari citra medis, sementara algoritma *K-Nearest Neighbors* (KNN) dan *Support Vector Machine* (SVM) banyak digunakan dalam klasifikasi penyakit berbasis pencitraan (Yopento et al., 2022). Pada penelitian ini, dilakukan perbandingan antara metode klasifikasi SVM dan KNN untuk mendapatkan akurasi terbaik dalam mendeteksi pneumonia berdasarkan fitur tekstur yang diperoleh dari GLCM.

Deteksi dini *pneumonia* sangat penting untuk meningkatkan hasil pasien dan mengurangi angka kematian yang terkait dengan kondisi pernapasan serius ini. Diagnosis yang tepat waktu memungkinkan perawatan yang lebih efektif, terutama pada populasi rentan seperti anak-anak dan lansia. Beberapa penelitian telah menunjukkan bahwa deteksi dini dapat menurunkan tingkat mortalitas secara signifikan (Ekananda & Rimirasih, 2022). Pasien dengan *pneumonia* yang didapat dari masyarakat (CAP) memiliki tingkat kematian jangka panjang yang tinggi, dengan sepertiga pasien rawat inap meninggal dalam setahun. Diagnosis dini juga memungkinkan pemberian antibiotik yang tepat waktu, yang sangat penting untuk *pneumonia* bakterial (Wijaya et al., 2020). Kemajuan teknologi dalam pembelajaran mesin telah memungkinkan pengembangan sistem berbasis kecerdasan buatan dengan akurasi hingga 97,58% dalam mendeteksi *pneumonia* dari citra rontgen dada (Baig et al., 2024; Nurhamzah et al., 2024). Selain itu, teknik pemrosesan citra seperti peregangan kontras dan pemerataan histogram telah meningkatkan kualitas gambar dan mempermudah diagnosis (Prasetyo & Ichwan, 2021). Berdasarkan deteksi yang lebih cepat dan akurat, sumber daya kesehatan dapat dialokasikan dengan lebih efisien, mengurangi beban rumah sakit dan memungkinkan strategi pencegahan yang lebih baik bagi populasi berisiko tinggi (Jawaz & Rahmadewi, 2024). Namun, ketergantungan pada sistem otomatis juga menghadirkan tantangan, seperti kebutuhan validasi ketat dan risiko ketergantungan berlebihan pada teknologi yang dapat menyebabkan kesalahan diagnosis jika tidak dikelola dengan baik.

Gray-Level Co-Occurrence Matrix (GLCM) merupakan salah satu metode utama dalam analisis tekstur yang banyak digunakan dalam pencitraan medis. GLCM bekerja dengan menganalisis hubungan spasial antara intensitas piksel dalam citra, memungkinkan ekstraksi fitur tekstur yang lebih informatif. Pada diagnostik medis, metode ini telah diterapkan secara luas, termasuk dalam klasifikasi tumor otak dengan kombinasi Pola Biner Lokal (LBP), yang mencapai akurasi 99,84% (Putra & Tahyudin, 2025). Selain itu, integrasi GLCM dengan fitur Tamura telah meningkatkan akurasi deteksi kanker payudara secara signifikan (Nugroho & Puspaningrum, 2021). Pada analisis patologi hati, optimasi GLCM terhadap peta T2 telah berhasil membedakan antara jaringan hati fibrotik dan sehat (Halimah & Anraeni, 2021). Tidak hanya dalam pencitraan medis, metode GLCM juga digunakan dalam inspeksi material, seperti pada deteksi *raveling* perkerasan aspal, di mana kombinasi GLCM dan LBP meningkatkan akurasi prediksi hingga 97% (Kartini et al., 2022). Walaupun metode ini memiliki banyak keunggulan, tantangan yang dihadapi termasuk kebutuhan komputasi yang tinggi serta potensi redundansi dalam ekstraksi fitur, yang dapat berdampak pada efisiensi dalam aplikasi real-time.

Perbandingan antara algoritma *K-Nearest Neighbors* (KNN) dan *Support Vector Machine* (SVM) telah menunjukkan efektivitas dalam klasifikasi *pneumonia* berbasis citra medis. Pendekatan ini bertujuan untuk mengevaluasi kinerja kedua algoritma dalam memproses fitur tekstur yang diperoleh dari GLCM. KNN bekerja dengan mengklasifikasikan data berdasarkan kedekatan fitur dan memiliki keuntungan dalam menangani data dengan distribusi non-linear, sementara SVM lebih unggul dalam membuat hyperplane yang optimal untuk pemisahan kelas (Wati et al., 2020). Studi terbaru menunjukkan bahwa SVM dapat mencapai akurasi 94% dan KNN 93,9% dalam deteksi pneumonia berbasis sinar-X dada (Kartini et al., 2022). Selain itu, kombinasi fitur yang diekstraksi menggunakan GLCM memungkinkan pemanfaatan optimal dalam kedua metode, sehingga membantu mengatasi masalah data tidak seimbang dan data yang hilang (Andika et al., 2019). Implementasi metode ini telah diuji dalam berbagai dataset medis dan menunjukkan peningkatan

presisi, recall, dan skor F1 dibandingkan dengan pendekatan (Subandi et al., 2024). Namun, tantangan utama dalam perbandingan ini adalah menentukan parameter optimal untuk setiap metode agar mencapai hasil terbaik.

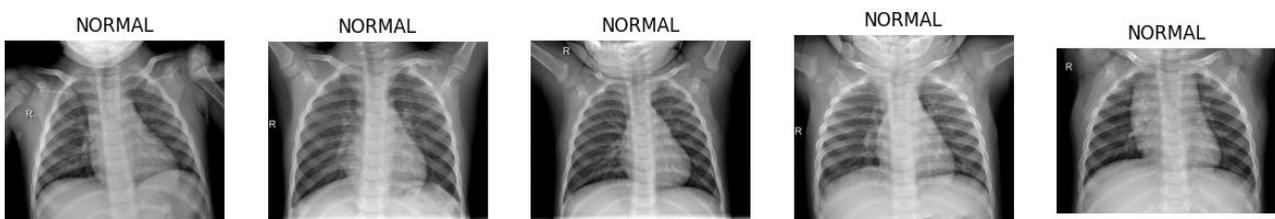
Meskipun berbagai penelitian telah menunjukkan efektivitas analisis tekstur berbasis GLCM serta klasifikasi berbasis KNN dan SVM dalam diagnosis medis, terdapat beberapa research gap yang masih perlu dieksplorasi. Pertama, banyak penelitian sebelumnya hanya menggunakan satu metode klasifikasi tanpa melakukan perbandingan langsung antara KNN dan SVM dalam konteks analisis tekstur untuk deteksi *pneumonia*. Kedua, belum banyak penelitian yang membahas dampak variasi parameter pada kedua algoritma dalam meningkatkan akurasi deteksi *pneumonia*. Ketiga, efek preprocessing citra terhadap hasil klasifikasi masih belum dikaji secara mendalam. Oleh karena itu, penelitian ini bertujuan untuk mengevaluasi dan membandingkan performa metode KNN dan SVM dalam klasifikasi pneumonia menggunakan fitur tekstur dari GLCM. Dengan pendekatan ini, diharapkan dapat diperoleh metode klasifikasi yang lebih optimal dalam mendukung diagnosis pneumonia berbasis citra rontgen secara akurat dan efisien.

B. METODE PENELITIAN

Penelitian ini dilakukan dengan pendekatan kuantitatif yang terdiri dari beberapa tahap utama, dimulai dari identifikasi masalah, pengumpulan data, ekstraksi fitur menggunakan metode GLCM, dan klasifikasi dengan algoritma KNN dan SVM. Sumber data yang digunakan adalah citra rontgen dada pada pasien anak berusia 1-5 tahun dari dataset yang tersedia secara publik sebanyak 5.863 citra. Setiap citra akan melalui tahap preprocessing untuk meningkatkan kualitas gambar sebelum dilakukan analisis tekstur. Berikut adalah alur untuk Langkah-langkah yang akan dilakukan pada penelitian ini.



Gambar 1. Langkah-langkah Penelitian



Gambar 1. *NORMAL* class

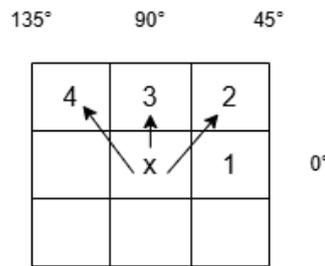


Gambar 3. *PNEUMONIA* class

Dataset terbagi menjadi data pelatihan dan data pengujian, dengan distribusi sebagai berikut: (1) *training data*: 5.216 gambar (1.341 gambar *normal*, 3.875 gambar *pneumonia*); dan (2) *testing data*: 624 gambar (234 gambar *normal*, 390 gambar *pneumonia*).

1. Ekstraksi Fitur dengan *Gray Level Co-Occurrence Matrix* (GLCM)

Ekstraksi fitur dalam dataset gambar bertujuan untuk mengubah data piksel mentah menjadi representasi numerik yang lebih bermakna, mengurangi dimensi data, meningkatkan efisiensi komputasi, dan membantu model *machine learning* dalam memahami serta mengenali pola dalam gambar secara lebih akurat. Metode ini digunakan untuk mengidentifikasi pola dan struktur tekstur dalam pemrosesan citra digital (Office et al., 2024). *Grey Level Co-occurrence Matrix* (GLCM), arah (q) mengacu pada sudut di mana hubungan antara pasangan piksel diukur, yaitu 0° (horizontal), 45° (diagonal naik), 90° (vertikal), dan 135° (diagonal turun). Jarak (d) menentukan seberapa jauh dua piksel yang dibandingkan satu sama lain dalam matriks GLCM untuk analisis tekstur suatu gambar. Berikut adalah rinciannya.



Gambar 4. Arah dan Jarak GLCM

Beberapa fitur dalam GLCM meliputi:

a. *Contrast*

Pada fitur ini fungsinya adalah untuk mengukur tingkat variasi keabuan antar referensi piksel dengan tetangga.

$$\sum_{n=0}^{N_g-1} |i - j|^2 * \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} P_{d,\theta}(i, j) \quad (1)$$

b. *Homogeneity*

Pada fitur ini mengukur keseragaman intensitas dalam citra. Nilai tinggi menunjukkan bahwa piksel-piksel memiliki intensitas yang mirip (tekstur halus).

$$\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \left(\frac{1}{1 + (i - j)^2} \right) * P_{d,\theta}(i, j) \quad (2)$$

c. *Energy*

Pada Fitur ini mengukur keberaturan pola dalam citra. Nilai tinggi menunjukkan pola yang sangat teratur atau memiliki struktur tertentu.

$$\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} P_{d,\theta}(i, j)^2 \quad (3)$$

d. *Correlation*

Pada fitur ini mengukur hubungan antara piksel tetangga dalam arah tertentu. Nilai tinggi menunjukkan piksel-piksel yang memiliki hubungan linier kuat.

$$\sum_{n=0}^{N_g-1} |i-j|^2 * \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} P_{d,\theta}(i,j) \frac{(i - \mu_x)(i - \mu_y)}{\sigma_x \sigma_y} \quad (4)$$

Dimana:

$$\mu_x = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} P_{d,\theta}(i,j) \quad (5)$$

$$\mu_y = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} P_{d,\theta}(i,j) \quad (6)$$

$$\sigma_x = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} (i, \mu)^2 * P_{d,\theta}(i,j) \quad (7)$$

$$\sigma_y = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} (i, \mu)^2 * P_{d,\theta}(i,j) \quad (8)$$

e. *Dissimilarity*

Pada fitur ini mengukur perbedaan intensitas antara pasangan piksel. Nilai tinggi menunjukkan perbedaan yang besar (tekstur kasar).

$$\sum_{i,j=0}^{N-1} P_{I,J|i-j|} \quad (9)$$

2. *K-Nearest Neighbor (KNN)*

K-Nearest Neighbor (KNN) Classifier merupakan metode yang digunakan untuk mengklasifikasikan objek berdasarkan data pembelajaran yang memiliki jarak terdekat dengan objek tersebut. Pada metode ini, data pembelajaran dipetakan ke dalam ruang berdimensi banyak, di mana setiap dimensi merepresentasikan fitur dari data tersebut. Pembagian ruang dimensi dilakukan berdasarkan klasifikasi data pembelajaran. Pemilihan nilai k yang optimal bergantung pada karakteristik data, di mana nilai k yang lebih besar dapat mengurangi efek noise dalam klasifikasi, tetapi juga membuat batas antara kelas menjadi kurang jelas. Untuk menentukan nilai k yang terbaik, dapat dilakukan optimasi parameter, seperti menggunakan metode cross-validation. Pada kasus khusus, klasifikasi dapat dilakukan berdasarkan satu data pembelajaran terdekat (dengan k = 1), yang dikenal sebagai algoritma nearest neighbor (Wati et al., 2020). Metode Euclidean Distance merupakan penghitungan jarak pada algoritma KNN yang paling banyak digunakan oleh peneliti. Rumus Rumus Euclidean Distance :

$$d(x,y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (10)$$

untuk,

D(x,y) = jarak antara data x ke data y

x_i = data testing ke-i

y_i = data training ke-i

n = dimensi data

3. Support Vector Machine (SVM)

Support Vector Machine, pada tahap ini, metode klasifikasi SVM diterapkan untuk membentuk classifier dalam bentuk *feature vector* guna memperoleh hasil prediksi pada data uji. SVM dapat dikategorikan untuk melihat sebab akibat antara satu variable dan variabel lainnya. Setelah melewati tahapan sebelumnya, hasil ekstraksi fitur diproses untuk membangun model klasifikasi SVM (Kartini et al., 2022).. Vektor yang telah dipetakan kemudian dihitung jaraknya, di mana jarak terjauh digunakan sebagai pemisah kelas. Sebuah hyperplane kemudian diterapkan untuk memisahkan dua kelas yang ada. Dalam pembuatan model klasifikasi SVM, langkah utama yang harus dilakukan adalah mengonversi dokumen ke dalam bentuk vektor. Berbagai variasi nilai diterapkan untuk menemukan kombinasi parameter yang dapat mencapai tingkat akurasi terbaik. Selanjutnya, dokumen uji dikonversi menjadi vektor, yang kemudian digunakan sebagai input ke dalam model SVM yang telah dibuat sebelumnya .

4. Pengujian

Model yang telah dibangun diuji menggunakan data validasi untuk memastikan parameter terbaik dari hasil *tuning hyperparameter*. Model kemudian diuji dengan data pengujian yang berisi citra *rontgen* kategori Normal dan Pneumonia. Evaluasi performa dilakukan ada banyak cara dengan menghitung metrik *accuracy*, *precision*, *recall*, dan *f1-score* untuk mengukur akurasi prediksi model. *Confusion matrix* juga digunakan untuk menganalisis hasil klasifikasi secara lebih mendetail, termasuk jumlah prediksi yang benar dan salah pada setiap kategori. Hasil pengujian ini menjadi dasar untuk mengevaluasi apakah model telah memenuhi tujuan penelitian dalam mendeteksi *pneumonia* dengan tingkat akurasi yang memadai (Ekananda & Rimirasih, 2022).

		True Values	
		Positive	Negative
Prediction	Positive	True Positive (TP)	False Negative (FN)
	Negative	False Positive (FP)	True Negative (TN)

Gambar 5. Confusion Matrix

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (11)$$

$$Precision = \frac{TP}{TP + FP} \times 100\% \quad (12)$$

$$Recall = \frac{TP}{TP + FN} \times 100\% \quad (13)$$

$$F1 = Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (14)$$

Keterangan:

TP: *True Positive* (Prediksi positif yang benar)

TN: *True Negative* (Prediksi negatif yang benar)

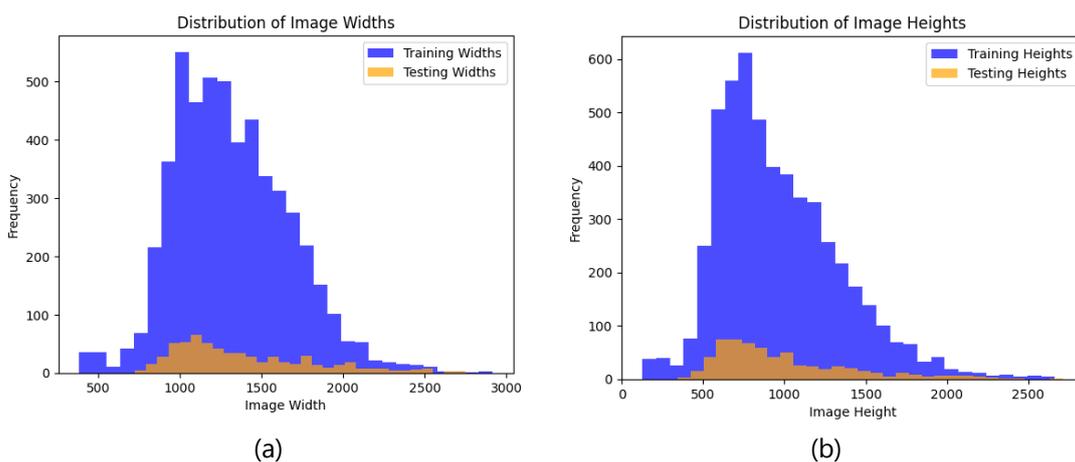
FP: *False Positive* (Prediksi positif yang salah)

FN: *False Negative* (Prediksi negatif yang salah)

C. HASIL DAN PEMBAHASAN

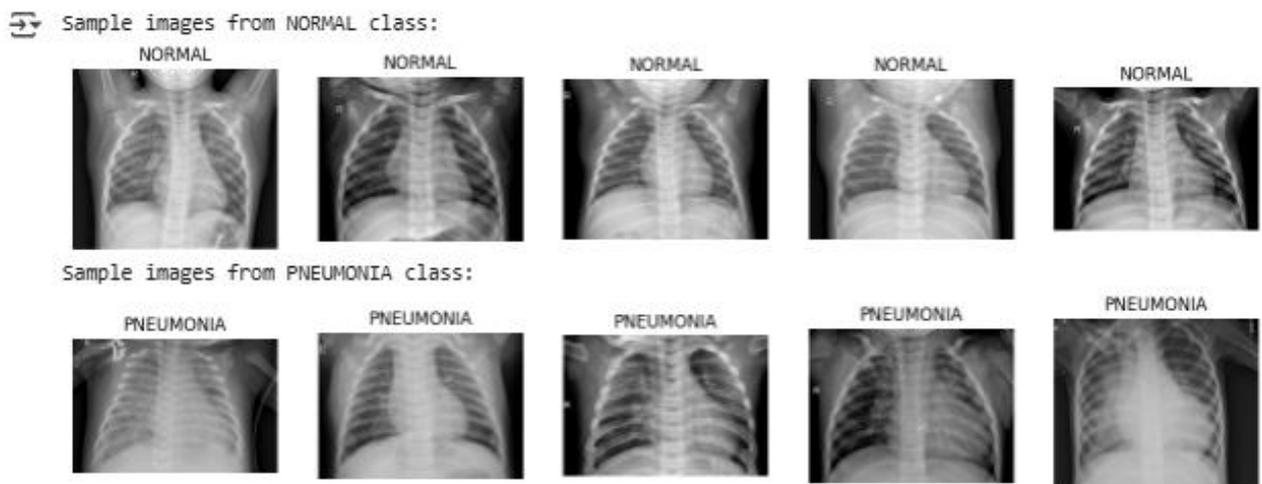
1. *Preprocessing* Data

Preprocessing data adalah tahapan awal dalam penelitian ini, yang bertujuan untuk meningkatkan kualitas gambar sebelum masuk ke tahap ekstraksi fitur dan klasifikasi. Dataset yang digunakan diperoleh dari Kaggle dan terdiri dari citra *rontgen* dada dengan dua kelas, yaitu Normal dan *Pneumonia*. Data ini kemudian dibagi menjadi dua kelompok: training dan testing, dengan jumlah data training 1341 citra untuk kelas Normal dan 3875 citra untuk kelas *Pneumonia*, serta data testing sebanyak 234 citra Normal dan 390 citra *Pneumonia*. Selanjutnya, dilakukan analisis ukuran gambar untuk mengetahui rata-rata dimensi citra dalam dataset. Rata-rata ukuran gambar dalam training set adalah 1320.61 x 968.07 piksel, sedangkan dalam testing set adalah 1388.13 x 991.71 piksel. Analisis ini penting untuk memastikan bahwa ukuran citra seragam sebelum masuk ke tahap pemrosesan lebih lanjut. Setelah semua gambar dikonversi ke grayscale, ukurannya kemudian diubah menjadi 300x300 piksel guna menstandarisasi dimensi dataset.



Gambar 6. Distribusi Lebar Gambar pada Data Pelatihan dan Pengujian (a), Distribusi Tinggi Gambar pada Data Pelatihan dan Pengujian (b)

Selanjutnya masih tahap *preprocessing*, dilakukan visualisasi beberapa sampel gambar dari kedua kelas untuk memahami perbedaan karakteristik visual antara kategori Normal dan *Pneumonia* sebelum memasuki tahap berikut.



Gambar 7. Visualisasi Sampel Gambar Normal dan *Pneumonia*

2. Ekstraksi fitur *Gray-Level Co-Occurrence Matrix* (GLCM)

Proses ekstraksi fitur merupakan langkah penting dalam pemrosesan data yang bertujuan untuk mengambil informasi relevan dari citra sehingga dapat digunakan dalam klasifikasi atau deteksi pola dalam *machine learning*. Pada penelitian ini, metode Gray-Level Co-Occurrence Matrix (GLCM) digunakan untuk menganalisis tekstur citra dengan mempelajari hubungan spasial antar piksel dalam tingkat keabuan tertentu. GLCM bekerja dengan menghitung frekuensi kemunculan pasangan piksel dalam empat orientasi berbeda (0° , 45° , 90° , dan 135°) dengan jarak satu piksel. Dari matriks ini, beberapa fitur tekstur utama diekstraksi, yaitu *dissimilarity* (mengukur ketidaksamaan tekstur), *energy* (mengukur keseragaman piksel), *contrast* (mengukur variasi keabuan), *correlation* (mengukur ketergantungan antar piksel), dan *homogeneity* (mengukur tingkat homogenitas tekstur). Setelah proses ini, citra direpresentasikan sebagai vektor fitur numerik yang digunakan dalam klasifikasi. Hasil ekstraksi fitur menghasilkan 5217 data training dan 625 data testing, masing-masing dengan 24 fitur yang siap digunakan dalam model klasifikasi.

Tabel 1. Hasil ekstraksi fitur GLCM

Fitur GLCM
contrast_0°
...
homogeneity_0°
...
energy_0°
...
correlation_0°
...
dissimilarity_0°
...
ASM_0°
...

3. Klasifikasi *K-Nearest Neighbor* (KNN)

Setelah data dari ekstraksi fitur tadi siap digunakan, pada implementasi klasifikasi dengan algoritma KNN Algoritma K-Nearest Neighbor (K-NN) digunakan untuk melakukan klasifikasi dengan mempertimbangkan kedekatan jarak antara suatu data dengan data lainnya. Parameter yang digunakan adalah *ne_neighbors*, *metric* ('*euclidean*', '*manhattan*') dan *weights* (uniform, distance). Selanjutnya dilakukan proses GridSearch didapatkan hasil Best Parameters: {'metric': '*manhattan*', '*n_neighbors*': 9, '*weights*': '*uniform*'} Best Cross-Validation Accuracy: 0.83. Kemudian dari hasil implementasi parameter tersebut dilakukan evaluasi pada data validasi didapatkan nilai sebesar 81%.

Tabel 2. Hasil Evaluasi Data Validasi KNN

Metric	Class 0 (NORMAL)	Class 1 (PNEUMONIA)	Macro Avg	Weighted Avg	Overall Accuracy
Precision	0.66	0.88	0.77	0.82	81.61%
Recall	0.70	0.86	0.78	0.82	
F1-Score	0.68	0.87	0.77	0.82	
Support	287	757	-	-	

Berdasarkan hasil evaluasi model, KNN menunjukkan performa terbaik pada $k = 5$, dengan akurasi validasi tertinggi 90,8%. Saat diuji pada data pengujian, akurasi menurun menjadi 69,87%, menunjukkan masih ada ruang untuk perbaikan. Model cukup baik dalam mendeteksi *Pneumonia* (*Precision* 70%, *Recall* 92%, *F1-score* 0.79), tetapi lemah dalam mengenali Normal (*Precision* 71%, *Recall* 33%, *F1-score* 0.45). Hal ini mengindikasikan bahwa model lebih cenderung mengklasifikasikan gambar sebagai *Pneumonia*, menyebabkan *False Positive* tinggi. Untuk

meningkatkan keseimbangan klasifikasi, dapat diterapkan oversampling pada kelas Normal, penggunaan CNN, atau eksplorasi fitur lain selain GLCM agar representasi citra lebih optimal. Selanjutnya adalah hasil dari *Confusion Matrix* pada implementasi algoritma KNN pada Tabel 3.

Tabel 3. *Confusion Matrix* Data Pengujian KNN

	Predicted Normal	Predicted Pneumonia
Actual Normal	110	124
Actual Pneumonia	40	350

Tabel 4. Hasil Evaluasi Data Pengujian KNN

Metric	Class 0 (NORMAL)	Class 1 (PNEUMONIA)	Macro Avg	Weighted Avg	Overall Accuracy
Precision	0.73	0.74	0.74	0.74	73.72%
Recall	0.47	0.90	0.68	0.74	
F1-Score	0.57	0.81	0.69	0.72	
Support	234	390	-	-	

Model KNN yang digunakan menunjukkan akurasi sebesar 73.7%, lebih rendah dari validasi awal (81%), dengan kinerja yang baik dalam mendeteksi *Pneumonia* (*Recall* 89.7%) namun kurang optimal dalam mengklasifikasikan pasien Normal (*Recall* 47%). *Precision* cukup seimbang untuk kedua kelas (73%), tetapi masih terdapat banyak *False Positive* (124 pasien Normal diklasifikasikan sebagai *Pneumonia*).

4. Klasifikasi *Support Vector Machine* (SVM)

Klasifikasi menggunakan *Support Vector Machine* (SVM) dilakukan dengan berbagai parameter, termasuk *C*, *kernel*, *degree*, dan *gamma*, untuk menemukan kombinasi terbaik yang menghasilkan akurasi optimal.

Tabel 5. Hasil Evaluasi SVM

Metric	Class 0 (NORMAL)	Class 1 (PNEUMONIA)	Macro Avg	Weighted Avg	Overall Accuracy
Precision	0.72	0.78	0.75	0.76	76.1%
Recall	0.59	0.86	0.73	0.76	
F1-Score	0.65	0.82	0.73	0.76	
Support	234	390	-	-	

Model dievaluasi menggunakan data pengujian untuk mengukur kinerjanya dalam mendeteksi *pneumonia*. Evaluasi kinerja dilakukan dengan mempertimbangkan metrik akurasi, *precision*, *recall*, dan *F1-score*, yang memberikan gambaran mengenai efektivitas dalam klasifikasi biner. Selain itu, distribusi prediksi dianalisis menggunakan *confusion matrix*, yang mencakup *True Positive*, *True Negative*, *False Positive*, dan *False Negative*. Pada hasil evaluasi data testing didapatkan hasil akurasi validasi sebesar 89%. Kemudian pada akurasi data pengujian atau testing akurasi menjadi 76.1%. Selanjutnya dilakukan tuning parameter dengan metode *GridSearch* berikut adalah hasil implementasi algoritma SVM dengan *tunning parameter*.

Tabel 6. *Confusion matrix* SVM

	Predicted Normal	Predicted Pneumonia
Actual Normal	138	96
Actual Pneumonia	53	337

Berdasarkan hasil di atas Jumlah kasus *Pneumonia* yang diklasifikasikan dengan benar sebagai *Pneumonia* adalah sebanyak 337, 138 Jumlah kasus Normal yang diklasifikasikan dengan benar sebagai Normal, 96 Jumlah kasus Normal yang salah diklasifikasikan sebagai *Pneumonia* (*False*

Alarm), 53 Jumlah kasus Pneumonia yang salah diklasifikasikan sebagai Normal (Missed Diagnosis). Dari hasil *confusion matrix* model berhasil mengidentifikasi Pneumonia dengan baik. Selanjutnya dilakukan proses *Tunning Parameter* untuk melihat performa SVM. Berikut adalah hasilnya. Hasil *tuning parameter* terbaik untuk SVM adalah $C = 1000$, $degree = 4$, $gamma = 1$, dan $kernel = poly$, dengan akurasi validasi meningkat hingga 93,97%, menunjukkan peningkatan performa model. Namun, perlu dianalisis lebih lanjut dampaknya terhadap data pengujian melalui *Confusion Matrix*.

Tabel 7. *Confusion Matrix SVM Best Parameters*

	Predicted Normal	Predicted Pneumonia
Actual Normal	82	152
Actual Pneumonia	18	372

Hasil dari tabel Model semakin agresif dalam mendeteksi *Pneumonia*, menyebabkan *False Positive* meningkat dari 96 menjadi 152 kasus, sehingga lebih banyak pasien Normal salah diklasifikasikan sebagai Pneumonia.

Tabel 8. Hasil Evaluasi *tuning test set SVM*

Metric	Class 0 (NORMAL)	Class 1 (PNEUMONIA)	Macro Avg	Weighted Avg	Overall Accuracy
Precision	0.82	0.71	0.76	0.75	72.76%
Recall	0.35	0.95	0.65	0.73	
F1-Score	0.49	0.81	0.65	0.69	
Support	234	390	-	-	

Setelah melakukan tuning parameter, akurasi keseluruhan menurun menjadi 72,76%. Meskipun model lebih baik dalam mendeteksi *Pneumonia*, kemampuannya dalam mengidentifikasi kasus Normal justru memburuk, berisiko menyebabkan overdiagnosis dan perawatan yang tidak diperlukan.

D. SIMPULAN DAN SARAN

Berdasarkan hasil evaluasi dan validasi, model *Support Vector Machine (SVM)* menunjukkan performa yang lebih unggul dibandingkan *K-Nearest Neighbors (KNN)* dalam klasifikasi *pneumonia*. Akurasi validasi awal SVM mencapai 89.46%, sedangkan akurasi pada data pengujian awal adalah 76.1%. Setelah dilakukan tuning pada model SVM, akurasi meningkat signifikan menjadi 93.97%, dengan *precision*, *recall*, dan *F1-score* yang lebih baik, terutama pada kelas *pneumonia*. Sementara itu, model KNN memiliki akurasi validasi 81.61% dan akurasi pengujian 73.72%, yang lebih rendah dibandingkan SVM. Selain itu, KNN menunjukkan performa yang kurang optimal dalam mengklasifikasikan kelas normal, sebagaimana terlihat pada nilai recall yang lebih rendah. Berdasarkan hasil ini, dapat disimpulkan bahwa SVM dengan tuning merupakan model terbaik dalam penelitian ini, dengan akurasi yang lebih tinggi dan performa yang lebih stabil dibandingkan KNN. Namun, ada beberapa saran untuk peningkatan lebih lanjut. Menyesuaikan threshold model untuk meningkatkan recall pada kelas Normal, menggunakan teknik SMOTE untuk penanganan ketidakseimbangan kelas, melakukan tuning lebih lanjut pada KNN dan mengkombinasikan model lain untuk mendapatkan akurasi lebih baik.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada semua pihak yang telah memberikan dukungan dan kontribusi dalam penyusunan paper ini, terutama kepada Ibu Nani Sulistianingsih, S.Kom.,M.Eng atas bimbingan, arahan, dan masukan berharga yang telah diberikan selama proses penelitian dan penulisan. Dukungan tersebut menjadi motivasi bagi penulis hingga penelitian ini dapat diselesaikan

dengan baik. Semoga hasil penelitian ini bermanfaat bagi perkembangan ilmu pengetahuan serta menjadi referensi yang berguna bagi para pembaca.

REFERENSI

- Andika, L. A., Pratiwi, H., & Handajani, S. S. (2019). Klasifikasi Penyakit Pneumonia Menggunakan Metode Convolutional Neural Network Dengan Optimasi Adaptive Momentum. *Journal Of Statistics And Its Applications*, 3(3), 331–340.
- Baig, M. D., Burhan, H., Haq, U., & Irshad, M. N. (2024). Pneumonia Detection Technique Empowered With Transfer Learning Approach. *Healthcraft Frontiers*, 3(4). <https://doi.org/10.56578/Hf020103>
- Ekananda, N. P., & Riminarsih, D. (2022). Identifikasi Penyakit Pneumonia Berdasarkan Citra Chest X-Ray Menggunakan Convolutional. *Jurnal Ilmiah Informatika Kompute*, 27(1), 79–94.
- Halimah, A. A. D., & Anraeni, S. (2021). Analisis Klasifikasi Dataset Citra Penyakit Pneumonia Menggunakan Metode K- Nearest Neighbor (Knn). *Indonesian Journal Of Data And Science*, 2(1), 1–12.
- Jawaz, I., & Rahmadewi, R. (2024). Sistem Deteksi Pneumonia Paru-Paru Dengan Pengolahan Citra Digital Dan Machine Learning. *Jurnal Ilmiah Teknik Elektro*, 5(2).
- Kartini, D., Farmadi, A., Nugrahadi, D. T., & Pirjatullah. (2022). Perbandingan Nilai K Pada Klasifikasi Pneumonia Anak Balita Menggunakan K-Nearest Neighbor. *Komputasi*, 10(1), 47–53.
- Nugroho, B., & Puspaningrum, E. Y. (2021). Kinerja Metode Cnn Untuk Klasifikasi Pneumonia Dengan Variasi Ukuran Citra Input. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 8(3), 533–538. <https://doi.org/10.25126/Jtiik.202184515>
- Nurhamzah, D., Sariyanto, I. W., Suwirmayanti, N. L. G. P., & Indrianto. (2024). Identifikasi Pneumonia Pada Citra Rontgen Paru-Paru Menggunakan Convolutional Neural Network. *Prosiding Seminar Hasil Penelitian Informatika Dan Komputer*, 1(3), 72–77.
- Office, I. H., Arifuddin, R., & Hidayatulail, B. F. (2024). Klasifikasi Pneumonia Menggunakan Metode Convolutional Neural Network. *Techné Jurnal Ilmiah Elektroteknika Vol.*, 23(2), 233–244.
- Prasetyo, R. R. E., & Ichwan, M. (2021). Perbandingan Metode Deep Residual Network 50 Dan Deep Residual Network 152 Untuk Deteksi Penyakit Pneumonia Pada Manusia. *Multimedia Artificial Intelligent Networking Database*, 6(2), 168–182.
- Putra, B. S. C., & Tahyudin, I. (2025). Performance Evaluation Of Cnn-Lstm And Cnn-Fnn Combinations For Pneumonia Classification Using Chest X-Ray Images. *Journal Of Informatics And Telecommunication Engineering*, 8(January), 196–207.
- Subandi, R., Herman, & Yudhana, A. (2024). Pre-Processing Pada Klasifikasi Citra Medis Pneumonia. *Pendidikan Teknologi Informasi*, 4(1), 86–93.
- Wati, R. A., Irsyad, H., & Rivan, M. E. Al. (2020). Klasifikasi Pneumonia Menggunakan Metode Support Vector Machine. *Jurnal Algoritme*, 1(1), 21–32.
- Wijaya, C., Irsyad, H., & Widhiarso, W. (2020). Klasifikasi Pneumonia Menggunakan Metode K- Nearest Neighbor Dengan Ekstraksi Glcm. *Jurnal Algoritme*, 1(1), 33–44.
- Yopento, J., Ernawati, & Coastera, F. F. (2022). Identifikasi Pneumonia Pada Citra X-Ray Paru-Paru Menggunakan Metode Convolutional Neural Network (Cnn) Berdasarkan Ekstraksi Fitur Sobel. *Jurnal Rekursif*, 10(1).