

MENGGUNAKAN METODE MACHINE LEARNING UNTUK KLASIFIKASI PNEUMONIA DARI CITRA X-RAY: STUDI PERBANDINGAN MODEL KLASIFIKASI

USING MACHINE LEARNING METHODS FOR CLASSIFYING PNEUMONIA FROM X-RAY IMAGES: A COMPARATIVE STUDY OF CLASSIFICATION MODELS

Ichtiar Akbar Sakti

Computer Science Master's Study Program, Nusa Mandiri University, Jakarta, Indonesia

14220032@nusamandiri.ac.id

ABSTRACT

Pneumonia is a respiratory illness that is still one of the top causes of death, especially in underdeveloped nations. Early diagnosis is critical, but human interpretation of chest X-ray pictures presents difficulties, particularly in areas with minimal medical professionals. The purpose of this study is to examine the effectiveness of multiple machine learning algorithms for categorizing chest X-ray pictures into two categories: pneumonia and normal. The dataset was obtained from Kaggle and then preprocessed and feature extracted using Histogram of Oriented Gradients (HOG), Local Binary Patterns (LBP), and Gabor Filters. Six machine learning methods were tested: SVM, Logistic Regression, K-Nearest Neighbors (KNN), Random Forest, Decision Tree, and Naive Bayes. Performance was evaluated utilizing criteria such as accuracy, precision, recall, F1-score, and ROC-AUC. The results indicated that SVM and Logistic Regression had the greatest accuracy (97% with an AUC of 1.00). KNN and Random Forest followed with 96% and 94% accuracies, respectively. In comparison, Decision Tree and Naive Bayes fared less well. These findings indicate that machine learning algorithms based on handcrafted feature extraction can be efficient and accurate tools for automatically detecting pneumonia from chest X-ray pictures, particularly in healthcare settings with restricted access to modern technologies.

Keywords: Feature Extraction, Image Classification, Machine Learning, Pneumonia, X-ray.

ABSTRAK

Pneumonia adalah penyakit pernapasan yang masih menjadi salah satu penyebab kematian teratas, terutama di negara-negara terbelakang. Diagnosis dini sangat penting, tetapi interpretasi manusia terhadap gambar rontgen dada menghadirkan kesulitan, terutama di daerah dengan tenaga medis yang minim. Tujuan dari penelitian ini adalah untuk menguji efektivitas beberapa algoritma pembelajaran mesin untuk mengkategorikan gambar rontgen dada menjadi dua kategori: pneumonia dan normal. Kumpulan data diperoleh dari Kaggle dan kemudian diproses terlebih dahulu dan diekstraksi fitur menggunakan Histogram of Oriented Gradients (HOG), Local Binary Patterns (LBP), dan Gabor Filters. Enam metode pembelajaran mesin diuji: SVM, Regresi Logistik, K-Nearest Neighbors (KNN), Random Forest, Decision Tree, dan Naive Bayes. Kinerja dievaluasi menggunakan kriteria seperti akurasi, presisi, recall, F1-score, dan ROC-AUC. Hasilnya menunjukkan bahwa SVM dan Regresi Logistik memiliki akurasi terbesar (97% dengan AUC 1,00). KNN dan Random Forest menyusul dengan akurasi masing-masing 96% dan 94%. Sebagai perbandingan, Decision Tree dan Naive Bayes kurang berhasil. Temuan ini menunjukkan bahwa algoritma pembelajaran mesin berdasarkan ekstraksi fitur buatan tangan dapat menjadi alat yang efisien dan akurat untuk mendeteksi pneumonia secara otomatis dari gambar rontgen dada, terutama di lingkungan layanan kesehatan dengan akses terbatas ke teknologi modern.

Kata Kunci: Ekstraksi Fitur, Klasifikasi Gambar, Pembelajaran Mesin, Pneumonia, Sinar-X

PENDAHULUAN

Pneumonia adalah salah satu jenis infeksi pada saluran pernapasan yang bisa berujung pada komplikasi serius dan kematian jika tidak segera dikenali dan diobati. Secara global, pneumonia tetap menjadi penyebab utama kematian pada anak-anak, orang tua, serta mereka yang memiliki masalah kesehatan lain, seperti

penyakit jantung dan diabetes [1], [2]. Organisasi Kesehatan Dunia (WHO) memperkirakan pneumonia bertanggung jawab atas lebih dari 2 juta kematian setiap tahunnya di seluruh dunia, terutama di negara-negara yang kurang berkembang, dengan tingkat kematian yang tinggi di kalangan balita dan orang tua. Di Indonesia, pneumonia adalah faktor utama penyebab

kematian pada anak-anak, dengan angka kematian yang terus menjadi perhatian besar bagi sektor kesehatan masyarakat.

Diagnosis pneumonia secara konvensional dilakukan melalui pemeriksaan fisik dan teknik pencitraan medis, seperti rontgen paru. Meski pemeriksaan rontgen paru sangat krusial, ada banyak rintangan dalam membaca hasil gambarnya, terutama di wilayah dengan kekurangan tenaga medis yang terlatih serta fasilitas kesehatan yang memadai. Kendala waktu, biaya tinggi, dan kurangnya sumber daya manusia untuk menganalisis gambar rontgen memperlambat proses diagnosis dan dapat menyebabkan kesalahan dalam penilaian. Untuk mengatasi permasalahan ini, diperlukan metode otomatis yang dapat mempercepat proses diagnosis serta memberikan hasil yang lebih tepat [3], [4], [5].

Seiring dengan kemajuan teknologi, Pembelajaran Mesin (ML) telah muncul sebagai pilihan yang menjanjikan dalam sektor kesehatan, terutama dalam analisis gambar medis [6], [7]. Pembelajaran Mesin memungkinkan pelatihan model menggunakan kumpulan data besar untuk secara otomatis mengambil fitur dari data mentah dan menghasilkan prediksi yang lebih cepat serta lebih tepat. Di antara berbagai metode Pembelajaran Mesin yang paling umum digunakan dalam pengolahan citra medis adalah Support Vector Machine (SVM), Random Forest, K-Nearest Neighbors (KNN), dan Naive Bayes (NB). Algoritma tersebut dapat digunakan untuk klasifikasi biner, seperti membedakan antara Pneumonia dan Normal dalam gambar rontgen dada, setelah gambar-gambar ini diubah menjadi fitur numerik [8], [9].

Penerapan Pembelajaran Mesin untuk mendeteksi pneumonia dalam foto rontgen dada melibatkan beberapa langkah krusial. Pertama, gambar medis harus diubah menjadi fitur numerik melalui metode ekstraksi fitur seperti Histogram Gradien Terarah (HOG) dan Pola Biner Lokal (LBP). Metode tersebut membantu model

dalam mengenali pola-pola penting dalam gambar, termasuk tekstur, bentuk, dan orientasi objek. Setelah fitur berhasil diekstrak, algoritma Pembelajaran Mesin diterapkan untuk mengklasifikasikan gambar rontgen ke dalam dua kategori: pneumonia dan normal [10], [11].

Penelitian ini memiliki tujuan untuk menggunakan teknik Pembelajaran Mesin dalam mendeteksi pneumonia melalui citra rontgen dada dengan memanfaatkan dataset Pneumonia yang dapat diakses di Kaggle. Dataset ini mencakup gambar rontgen dada yang telah dibagi menjadi dua kategori, yaitu pneumonia dan normal. Tidak seperti metode Pembelajaran Mendalam yang secara langsung memanfaatkan jaringan saraf untuk pengambilan fitur, pendekatan Pembelajaran Mesin ini mengharuskan pengambilan fitur terlebih dahulu sebelum melatih model dengan berbagai algoritma Pembelajaran Mesin seperti SVM, Random Forest, KNN, Logistic Regression, dan Naive Bayes.

Salah satu alasan penting mengapa Machine Learning dipakai dalam studi ini adalah untuk menilai seberapa baik algoritma konvensional dalam menjalankan tugas klasifikasi gambar medis, yang biasanya lebih sering menggunakan metode Deep Learning. Dengan membandingkan berbagai algoritma Machine Learning, diharapkan akan teridentifikasi model yang menawarkan kinerja terbaik dalam mendeteksi pneumonia pada foto rontgen dada.

Selain itu, studi ini juga memiliki tujuan untuk memberikan sumbangan dalam pengembangan sistem diagnosis otomatis yang lebih mudah diakses, khususnya di wilayah yang memiliki keterbatasan dalam hal fasilitas kesehatan dan tenaga medis. Dengan pemanfaatan Machine Learning, diharapkan proses identifikasi pneumonia dapat dilakukan dengan lebih cepat, efisien, dan dengan biaya yang lebih rendah, serta menghasilkan data yang tepat untuk membantu dokter dalam membuat keputusan yang lebih baik.

Berbagai studi terdahulu telah menunjukkan efektivitas Machine Learning dalam menilai gambar medis. Model SVM mampu meraih tingkat akurasi yang sangat tinggi dalam mengkategorikan gambar rontgen dada untuk mengidentifikasi pneumonia [12], [13]. Metode Random Forest digunakan untuk mendeteksi pneumonia dalam gambar rontgen dada dan memperoleh hasil yang memuaskan. KNN diterapkan untuk mengklasifikasikan pneumonia, yang menunjukkan bahwa meskipun metode ini sederhana, KNN tetap mampu memberikan akurasi yang baik pada dataset dengan jumlah gambar yang tidak terlalu banyak.

Penelitian ini bertujuan untuk menyelidiki dan membandingkan sejumlah model Pembelajaran Mesin untuk menemukan model yang paling efektif dalam mendeteksi pneumonia melalui gambar sinar-X dada, serta menilai kinerja model-model tersebut dengan menggunakan metrik akurasi, presisi, recall, dan F1-score. Melalui metode ini, diharapkan dapat menawarkan solusi yang lebih efisien yang dapat diakses oleh lebih banyak fasilitas kesehatan.

METODE PENELITIAN

Untuk melakukan penelitian ini, langkah-langkah yang dilakukan untuk

mendapatkan hasil ditunjukkan pada Gambar 1.

2.1. Pengumpulan Dataset


Dataset yang digunakan dalam penelitian ini adalah data Citra X-Ray Pneumonia yang tersedia di Kaggle. Dataset ini terdiri dari gambar rontgen dada yang dikategorikan menjadi dua kelas:

- Pneumonia : Gambar menunjukkan tanda-tanda pneumonia.
- Normal : Gambar menunjukkan kondisi normal tanpa pneumonia.

Jumlah gambar dalam dataset ini bervariasi, dan data dibagi menjadi dua bagian:

- Data Pelatihan (Training Data): untuk melatih model ini, data yang digunakan sekitar 70-80% sehingga model dapat mempelajari pola dari gambar rontgen dada.
- Data Pengujian (Test Data): total data digunakan untuk menguji kinerja model yang telah dilatih Sekitar 20-30%. Data ini tidak digunakan dalam pelatihan dan bertujuan untuk mengevaluasi akurasi model.

Tahap awal untuk menyiapkan dataset adalah melakukan pemrosesan awal guna memastikan bahwa gambar-gambar dalam dataset memiliki ukuran yang konsisten dan nilai piksel yang dinormalisasi.



Gambar 1. Tahapan Penelitian

2.2. Ekstraksi Fitur Gambar

Pada penelitian ini, untuk menerapkan metode Machine Learning tradisional, gambar rontgen dada yang berformat citra perlu dikonversi menjadi fitur numerik yang dapat dipahami oleh algoritma machine learning. Oleh karena itu, langkah selanjutnya adalah ekstraksi fitur dari gambar menggunakan beberapa teknik yang umum dalam pengolahan citra. Teknik ekstraksi fitur yang digunakan adalah:

- Histogram of Oriented Gradients (HOG): Teknik ini digunakan untuk mendeteksi bentuk dan kontur pada gambar dengan menghitung gradien pada piksel gambar. HOG efektif untuk mendeteksi objek dalam gambar [14].
- Local Binary Patterns (LBP): Digunakan untuk menganalisis tekstur gambar. LBP bekerja dengan mendeteksi pola-pola lokal di setiap area gambar, yang penting untuk mengenali tekstur tertentu pada gambar medis [15].
- Gabor Filters: Gabor Filters digunakan untuk mengekstrak fitur tekstur di gambar. Fitur ini berguna untuk mengenali pola tekstur tertentu dalam gambar medis seperti rontgen dada [16].

Setelah fitur diekstraksi, gambar rontgen akan dikonversi menjadi vektor fitur yang digunakan sebagai input untuk algoritma Machine Learning.

2.3. Pembagian Data

Setelah ekstraksi fitur selesai, data dibagi menjadi dua bagian:

- Data Pelatihan (Training Data): Sekitar 70-80% dari data yang telah diekstraksi fitur digunakan untuk melatih model.
- Data Pengujian (Test Data): 20-30% dari data digunakan untuk menguji kinerja model yang telah dilatih.

Pembagian data dilakukan secara acak dengan menggunakan fungsi `train_test_split` dari `scikit-learn` untuk memastikan bahwa data pelatihan dan pengujian terdistribusi secara merata.

2.4. Penerapan Model Machine Learning

Untuk menganalisis dataset dan mendeteksi pneumonia, beberapa algoritma Machine Learning diterapkan, dengan tujuan untuk membandingkan kinerja masing-masing model. Berikut adalah model-model yang diterapkan:

2.4.1. Logistic Regression

Logistic Regression adalah model klasifikasi yang digunakan untuk memetakan probabilitas dan menghasilkan keputusan dalam kasus klasifikasi biner [17]. Model ini sangat sederhana dan efektif untuk masalah yang tidak terlalu kompleks.

$$P(y = 1 | x) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n)}}$$

- $P(y = 1|x)$: Probabilitas output kelas 1
- β_0 : Intersep
- β_i : Koefisien fitur
- x_i : Nilai fitur ke-i

2.4.2. Decision Tree

Decision Tree adalah model klasifikasi berbasis pohon keputusan yang membagi data menjadi beberapa bagian berdasarkan fitur. Model ini menghasilkan keputusan berdasarkan aturan yang mudah dipahami dan sangat baik dalam menangani data yang bersifat non-linear [18].

Pemilihan split berdasarkan impurity :

- Gini Index :

$$Gini = 1 - \sum_{i=1}^c p_i^2$$

- Entropy :

$$Entropy = - \sum_{i=1}^c p_i \log_2 p_i$$

Pilih split dengan *information gain* tertinggi :

$$IG = Entropy_{parent} - \sum \frac{n_{child}}{n_{total}} \cdot Entropy_{child}$$

2.4.3. Random Forest

Random Forest adalah model ensemble yang menggabungkan beberapa pohon keputusan untuk menghasilkan prediksi yang lebih kuat dan lebih akurat.

Setiap pohon keputusan bekerja secara independen dan memberikan hasil yang berbeda, dan hasil akhir diambil dengan melakukan voting [19]. Tidak ada satu rumus spesifik, tetapi intinya:

- Buat banyak Decision Tree dari subset acak data dan fitur.
- Hasil klasifikasi :

$$\hat{y} = \text{mode}(T_1(x), \dots, T_m(x))$$
- $T_i(x)$: Prediksi dari pohon ke-i

2.4.4. Support Vector Machine (SVM)

SVM adalah algoritma klasifikasi yang mencari garis atau hyperplane terbaik untuk memisahkan data ke dalam dua kelas. Kernel RBF (Radial Basis Function) digunakan untuk menangani masalah klasifikasi non-linear [20].

Rumus :

$$f(x) = w^T x + b$$

Hyperplane Optimal :

$$\min_{w,b} \frac{1}{2} ||w||^2 \text{ dengan syarat : } y_i(w^T x_i + b) \geq 1$$

Untuk non-linier, digunakan kernel $K(x_i, x_j)$.

2.4.5. K-Nearest Neighbors (KNN)

KNN adalah algoritma yang mengklasifikasikan data berdasarkan kedekatannya dengan data lain dalam ruang fitur. Ini adalah model yang mudah dipahami dan sering digunakan untuk dataset yang relatif kecil [21]. Rumus jarak:

$$d(x, x_i) = \sqrt{\sum_{j=1}^n (x_j - x_{ij})^2}$$

- x : Titik data baru
- x_i : Titik data tetangga
- Kelas ditentukan berdasarkan mayoritas dari K tetangga terdekat

2.4.6. Naive Bayes

Naive Bayes adalah model probabilistik yang digunakan untuk klasifikasi berdasarkan Teorema Bayes dengan asumsi independen antara fitur.

Model ini sering digunakan pada dataset dengan banyak fitur, seperti gambar medis [22].

$$P(C_k|x) = \frac{P(C_k) \cdot \prod_{i=1}^n P(x_i|C_k)}{P(x)}$$

- $P(C_k|x)$: Probabilitas kelas C_k diberikan data x
- $P(C_k)$: Probabilitas awal kelas
- $P(x_i|C_k)$: Probabilitas fitur ke-I dengan syarat kelas C_k

Catatan : untuk klasifikasi, kita ambil kelas dengan probabilitas terbesar

$$\hat{y} = \arg \max_{C_k} P(C_k|x)$$

2.5. Evaluasi Model

Setelah model dilatih, setiap model dievaluasi menggunakan data pengujian untuk mengukur performanya. Metrik yang digunakan untuk evaluasi adalah:

- Akurasi : Persentase prediksi yang benar dari total prediksi.
- Precision : Kemampuan model untuk mengidentifikasi kelas positif (Pneumonia) dengan benar.
- Recall : Kemampuan model untuk menemukan semua contoh positif yang sebenarnya.
- F1-Score : Kombinasi antara precision dan recall, terutama ketika data tidak seimbang.
- Confusion Matrix: Untuk memvisualisasikan distribusi prediksi yang benar dan salah dalam setiap kelas.

2.6. Perbandingan Kinerja Model

Setelah evaluasi, kinerja model-model yang diterapkan akan dibandingkan berdasarkan metrik yang telah disebutkan di atas. Model yang memiliki performa terbaik akan dipilih untuk diterapkan pada prediksi data nyata.

HASIL DAN PEMBAHASAN

3.1. Hasil Accuracy

Dalam penelitian ini, enam algoritma machine learning tradisional diuji untuk mengklasifikasikan pneumonia dari citra X-ray, yakni Support Vector Machine

(SVM), Logistic Regression, K-Nearest Neighbors (KNN), Random Forest, Decision Tree dan Naive Bayes. Hasil evaluasi menunjukkan bahwa SVM dan Logistic Regression merupakan dua model dengan performa terbaik, masing-masing mencapai akurasi sebesar 97%. Kinerja tinggi dari kedua model ini menunjukkan bahwa pola visual pada citra X-ray dapat dipelajari secara efektif bahkan oleh model linear seperti Logistic Regression, maupun oleh SVM yang dikenal andal untuk data berdimensi tinggi [23].

Model KNN menyusul dengan akurasi 96%, menunjukkan bahwa pendekatan berbasis kedekatan antar fitur

citra juga mampu mengenali pola pneumonia dengan baik. Random Forest, yang merupakan ensemble dari banyak pohon keputusan, memperoleh akurasi 94%—cukup baik, namun sedikit tertinggal karena kemungkinan adanya redundansi atau kurang optimal dalam pemisahan kelas yang kompleks. Sebaliknya, Decision Tree tunggal dan Naive Bayes menunjukkan performa terendah dengan akurasi hanya 87%. Hasil ini mencerminkan kelemahan model tersebut yang cenderung overfitting terhadap data latih dan tidak mampu menggeneralisasi dengan baik pada data uji. Tabel 1.

Tabel 1. Nilai Accuracy

Algorithm	Accuracy	Precision	Recall	F1 Score
LR	97%	0.95/0.97	0.93/0.98	0.94/0.98
DT	87%	0.78/0.91	0.76/0.92	0.77/0.91
RF	94%	0.93/0.94	0.84/0.98	0.88/0.96
SVM	97%	0.95/0.98	0.95/0.98	0.95/0.98
KNN	96%	0.90/0.98	0.96/0.96	0.93/0.97
NB	87%	0.71/0.97	0.92/0.85	0.80/0.90

3.2. Pembahasan


Hasil evaluasi menunjukkan bahwa model Support Vector Machine (SVM) dan Logistic Regression memberikan akurasi tertinggi, masing-masing sebesar 97%. SVM menunjukkan kinerja yang sangat stabil dan konsisten dalam membedakan citra dada yang mengandung pneumonia dan yang normal. Dengan precision dan recall yang tinggi pada kedua kelas, SVM menjadi model paling andal dalam penelitian ini. Menariknya, Logistic Regression yang merupakan model linear dan sederhana juga mampu mencapai tingkat akurasi yang sama dengan SVM. Hal ini mengindikasikan bahwa fitur-fitur yang diekstraksi (HOG dan LBP) cukup representatif untuk membedakan dua kelas utama. Sementara itu, model K-Nearest Neighbors (KNN) juga menunjukkan performa yang baik dengan akurasi 96%, meskipun model ini relatif lebih sensitif terhadap outlier dan perbedaan skala data. Random Forest, yang merupakan metode ensemble dari beberapa pohon keputusan,

memberikan akurasi 94% dan performa yang cukup seimbang.

Di sisi lain, Decision Tree dan Naive Bayes menunjukkan hasil paling rendah, yaitu 87%, serta cenderung mengalami overfitting terhadap data latih. Ini terlihat dari nilai recall pada kelas normal yang jauh lebih rendah dibanding model lainnya. Secara umum, akurasi 97% berarti bahwa dari total 1.044 citra uji, sekitar 1.012 citra diklasifikasikan dengan benar, sementara hanya sekitar 32 citra yang mengalami kesalahan klasifikasi. Dalam konteks klasifikasi medis, nilai recall untuk kelas positif (penderita pneumonia) menjadi sangat penting, dan model SVM terbukti unggul dalam aspek ini. Oleh karena itu, SVM dan Logistic Regression direkomendasikan sebagai model awal dalam sistem deteksi otomatis pneumonia dari citra X-ray, sedangkan model Random Forest dan KNN dapat dijadikan alternatif tambahan. Model Decision Tree sebaiknya dihindari atau diperbaiki lebih lanjut melalui teknik pruning atau ensemble.

3.3. Visualisasi Hasil

Visualisasi confusion matrix dan akurasi antar model menunjukkan dominasi performa model SVM dalam mengklasifikasikan pneumonia secara tepat.



Gambar 2. Confusion Matrix

Berdasarkan heatmap tersebut, dapat dilihat bahwa Logistic Regression, SVM,

dan KNN menunjukkan hasil prediksi yang sangat akurat. Misalnya, pada Logistic Regression, terdapat 270 data Normal yang diprediksi dengan benar dan 738 data Pneumonia yang diklasifikasikan secara tepat, dengan hanya 36 kesalahan klasifikasi. SVM bahkan menunjukkan tingkat kesalahan yang lebih rendah dengan hanya 29 kesalahan dari total 1044 citra uji. Warna biru tua yang mendominasi diagonal heatmap pada model-model ini menandakan konsistensi dalam prediksi benar antara label aktual dan prediksi.

Sementara itu, Decision Tree menunjukkan performa yang lebih rendah, dengan 68 kasus Normal yang salah diklasifikasikan sebagai Pneumonia dan 56 kasus Pneumonia yang salah diklasifikasikan sebagai Normal. Hal ini tercermin dari warna yang lebih terang di luar diagonal utama, menandakan kesalahan klasifikasi yang lebih banyak.


Naive Bayes juga menunjukkan tingkat kesalahan yang cukup tinggi, terutama dalam mengklasifikasikan Pneumonia, dengan 112 citra Pneumonia yang salah diklasifikasikan sebagai Normal. Hal ini menunjukkan bahwa Naive Bayes memiliki keterbatasan dalam menangkap kompleksitas data citra X-ray, kemungkinan disebabkan oleh asumsi independensi antar fitur yang tidak terpenuhi dalam data visual.

3.4. ROC Curve

visualisasi ROC Curve memberikan gambaran menyeluruh tentang kemampuan diskriminatif dari masing-masing model. ROC Curve menunjukkan bahwa Logistic Regression dan SVM memiliki nilai AUC (Area Under Curve) sebesar 1.00, yang berarti kedua model ini mampu membedakan secara sempurna antara pasien pneumonia dan non-pneumonia.

Random Forest dan KNN juga menunjukkan performa yang sangat baik dengan AUC sebesar 0.99. Naive Bayes mencatatkan AUC 0.94, masih tergolong sangat baik. Sementara itu, Decision Tree memiliki AUC paling rendah yaitu 0.85,

mengindikasikan keterbatasan model ini dalam memisahkan dua kelas secara akurat. Semakin besar AUC, semakin baik kemampuan model dalam membedakan dua kelas. Oleh karena itu, ROC Curve menguatkan hasil sebelumnya bahwa SVM dan Logistic Regression adalah pilihan terbaik untuk klasifikasi citra pneumonia.



Gambar 3. visualisasi ROC Curve

SIMPULAN

Penelitian ini membuktikan bahwa metode machine learning tradisional dapat digunakan secara efektif untuk mendeteksi pneumonia dari citra X-ray dada. Dari enam algoritma yang diuji, Support Vector Machine (SVM) dan Logistic Regression menunjukkan performa terbaik dengan akurasi masing-masing sebesar 97%, precision dan recall tinggi, serta AUC sempurna (1.00). Hal ini menunjukkan bahwa kedua model mampu mengidentifikasi pola visual pneumonia dengan sangat akurat, bahkan dalam kondisi dataset terbatas.

Model K-Nearest Neighbors (KNN) dan Random Forest juga menunjukkan kinerja yang kompetitif, masing-masing dengan akurasi 96% dan 94%, serta performa stabil pada metrik evaluasi lainnya. Sebaliknya, Decision Tree dan Naive Bayes mencatatkan akurasi terendah (87%) dan kesulitan dalam menggeneralisasi data uji, terutama karena kecenderungan overfitting dan asumsi independensi fitur

yang tidak sesuai dengan karakteristik data citra.

Secara keseluruhan, hasil penelitian ini mengindikasikan bahwa pendekatan machine learning berbasis ekstraksi fitur (HOG, LBP, Gabor) mampu memberikan hasil klasifikasi yang sangat baik untuk deteksi pneumonia, bahkan tanpa menggunakan deep learning [24]. SVM dan Logistic Regression direkomendasikan sebagai model dasar untuk sistem diagnosis otomatis, terutama pada lingkungan dengan keterbatasan sumber daya komputasi [25], [26]. Penelitian ini juga membuka peluang untuk eksplorasi model ensemble dan penggabungan teknik explainability untuk meningkatkan kepercayaan pengguna klinis terhadap sistem.

DAFTAR PUSTAKA

- [1] G. R. Ferreira and I. P. Marangoni, "Hospital morbidity and mortality profile due to pneumonia in Brazil between 2010 and 2020," in *II INTERNATIONAL SEVEN MULTIDISCIPLINARY CONGRESS*, Seven Congress, Aug. 2023. doi: 10.56238/homeinternationalanais-080.
- [2] J. Tomys-Składowska *et al.*, "Pneumonia in Geriatric Patients: Focus on Etiology, Clinical Features, Diagnosis, and Prevention," *J. Health Study Med.*, vol. 2023, no. 1, pp. 375–398, Jan. 2023, doi: 10.2478/jhsm-2023-0017.
- [3] Unit of Scientific Research, Applied College, Qassim University, Buraydah, Saudi Arabia, I. Imène, Department of Information Technology, College of Computer, Qassim University, Buraydah, Saudi Arabia, and A. Selmi, "Modelling of Neutrosophic Set-Based k-Nearest Neighbors Classifier for Virus Pneumonia and COVID-19 Recognition," *Int. J. Neutrosophic Sci.*, vol. 25, no. 1, pp. 64–74, 2025, doi: 10.54216/IJNS.250105.

- [4] S. R. Howie, D. H. Hamer, and S. M. Graham, "Pneumonia." International Encyclopedia of Public Health, 2020.
- [5] A. K. Asok and L. L. Thampi, "Automated Diagnosis of Covid-19 and Pneumonia Using Transfer Learning and Custom Segmentation on Chest X-Ray Images," *WSEAS Trans. Comput. Res.*, vol. 12, pp. 328–335, Jun. 2024, doi: 10.37394/232018.2024.12.32.
- [6] R. Castellano Ontiveros, M. Elgendi, and C. Menon, "A machine learning-based approach for constructing remote photoplethysmogram signals from video cameras," *Commun. Med.*, vol. 4, no. 1, p. 109, Jun. 2024, doi: 10.1038/s43856-024-00519-6.
- [7] G. M. Raj, S. Dananjayan, and K. K. Gudivada, "Applications of artificial intelligence and machine learning in clinical medicine: *What lies ahead ?*," *Med. Adv.*, vol. 2, no. 2, pp. 202–204, Jun. 2024, doi: 10.1002/med4.62.
- [8] S. Jasthy, K. Ramasubramanian, R. Vangipuram, and S. Bollu, "Comparative Analysis of Machine-Learning Algorithms for Accurate Diagnosis of Lung Diseases Using Chest X-ray Images: A Study on Balanced and Unbalanced Data on Segmented and Unsegmented Images," *Cureus*, Jan. 2024, doi: 10.7759/cureus.53282.
- [9] R. T. Sousa, O. Marques, F. A. A. M. N. Soares, I. I. G. Sene, L. L. G. De Oliveira, and E. S. Spoto, "Comparative Performance Analysis of Machine Learning Classifiers in Detection of Childhood Pneumonia Using Chest Radiographs," *Procedia Comput. Sci.*, vol. 18, pp. 2579–2582, 2013, doi: 10.1016/j.procs.2013.05.444.
- [10] M. Mujahid *et al.*, "Pneumonia detection on chest X-rays from Xception-based transfer learning and logistic regression," *Technol. Health Care*, vol. 32, no. 6, pp. 3847–3870, Nov. 2024, doi: 10.3233/THC-230313.
- [11] Q. An, W. Chen, and W. Shao, "A Deep Convolutional Neural Network for Pneumonia Detection in X-ray Images with Attention Ensemble," *Diagnostics*, vol. 14, no. 4, p. 390, Feb. 2024, doi: 10.3390/diagnostics14040390.
- [12] A. Prastyo, S. Sutikno, and K. Khadijah, "Improving support vector machine and backpropagation performance for diabetes mellitus classification," *Comput. Sci. Inf. Technol.*, vol. 5, no. 2, pp. 140–149, Jul. 2024, doi: 10.11591/csit.v5i2.pp140-149.
- [13] H. J. Shin, E. H. Lee, K. Han, L. Ryu, and E.-K. Kim, "Development of a new prognostic model to predict pneumonia outcome using artificial intelligence-based chest radiograph results," *Sci. Rep.*, vol. 14, no. 1, p. 14415, Jun. 2024, doi: 10.1038/s41598-024-65488-1.
- [14] R. Aldamani, D. A. Abuhani, and T. Shanableh, "LungVision: X-ray Imagery Classification for On-Edge Diagnosis Applications," *Algorithms*, vol. 17, no. 7, p. 280, Jun. 2024, doi: 10.3390/a17070280.
- [15] N. S. Fatimah and S. Agustin, "Klasifikasi Citra Batik Menggunakan Local Binary Pattern (LBP) dan Support Vector Machine (SVM)," vol. 22, no. 1, 2025.
- [16] Department of Computer Engineering, Faculty of Engineering, Halic University, Istanbul, Turkey and M. S. Khalil, "Deducting Abnormalities in Chest X-Rays using Gabor Filters and Deep Neural Network (DNN)," *J. Kejuruter.*, vol. 36, no. 5, pp. 1965–1972, Sep. 2024, doi: 10.17576/jkukm-2024-36(5)-16.
- [17] N. Alangari and R. Alturki, "Predicting Students Final GPA using 15 Classification Algorithms".
- [18] E. Demirović and P. J. Stuckey, "Optimal Decision Trees for

- Nonlinear Metrics,” *Proc. AAAI Conf. Artif. Intell.*, vol. 35, no. 5, pp. 3733–3741, May 2021, doi: 10.1609/aaai.v35i5.16490.
- [19] R. Natras, B. Soja, and M. Schmidt, “Ensemble Machine Learning of Random Forest, AdaBoost and XGBoost for Vertical Total Electron Content Forecasting,” *Remote Sens.*, vol. 14, no. 15, p. 3547, Jul. 2022, doi: 10.3390/rs14153547.
- [20] A. Razaque, M. Ben Haj Frej, M. Almi’ani, M. Alotaibi, and B. Alotaibi, “Improved Support Vector Machine Enabled Radial Basis Function and Linear Variants for Remote Sensing Image Classification,” *Sensors*, vol. 21, no. 13, p. 4431, Jun. 2021, doi: 10.3390/s21134431.
- [21] L. Hakim, A. Sobri, L. Sunardi, and D. Nurdiansyah, “Prediksi penyakit jantung berbasis mesin learning dengan menggunakan metode k-nn,” vol. 07, no. 02, 2024.
- [22] M. I. Ghozali, W. H. Sugiharto, and A. F. Iskandar, “Analisis Sentimen Pinjaman Online Di Media Sosial Twitter Menggunakan Metode Naive Bayes”.
- [23] M. Turkoglu, “COVIDetectionNet: COVID-19 diagnosis system based on X-ray images using features selected from pre-learned deep features ensemble,” *Appl. Intell.*, vol. 51, no. 3, pp. 1213–1226, Mar. 2021, doi: 10.1007/s10489-020-01888-w.
- [24] J. N. Hasoon *et al.*, “COVID-19 anomaly detection and classification method based on supervised machine learning of chest X-ray images,” *Results Phys.*, vol. 31, p. 105045, Dec. 2021, doi: 10.1016/j.rinp.2021.105045.
- [25] A. C. Muhammad, B. Engg, and M. Engg, “Dasar-dasar Pembelajaran Mesin”.
- [26] R. Guido, S. Ferrisi, D. Lofaro, and D. Conforti, “An Overview on the Advancements of Support Vector Machine Models in Healthcare Applications: A Review,” *Information*, vol. 15, no. 4, p. 235, Apr. 2024, doi: 10.3390/info15040235.