



# Klasifikasi Penyakit Pneumonia Menggunakan Regresi Logistik, SVM, dan Fitur Deep Learning

Ahmad Bagus Muzakki\*, Imam Yuadi

Program Studi Sains Informasi dan Perpustakaan, Universitas Airlangga, Surabaya, Indonesia

Email: <sup>1</sup>\*ahmad-bagus-muzakki-2025@fisip.unair.com, <sup>2</sup>imam.yuadi@fisip.unair.ac.id

Email Penulis Korespondensi: ahmad-bagus-muzakki-2025@fisip.unair.com

**Abstrak**—Penelitian ini mengevaluasi integrasi antara ekstraksi fitur berbasis deep learning dengan algoritma machine learning konvensional untuk klasifikasi penyakit pneumonia dari citra rontgen dada. Dua model pra-latih, yaitu Inception V3 dan SqueezeNet, digunakan sebagai feature extractor karena kemampuannya dalam menghasilkan representasi fitur yang efektif dari citra medis. Inception V3 dipilih karena mampu menangkap pola visual yang kompleks, sedangkan SqueezeNet menawarkan efisiensi komputasi dengan jumlah parameter yang lebih sedikit. Sementara itu, Logistic Regression dan Support Vector Machine (SVM) digunakan sebagai algoritma klasifikasi karena kemampuannya dalam menangani data berdimensi tinggi hasil ekstraksi fitur deep learning. Dataset yang digunakan terdiri atas dua kategori, yaitu citra normal dan citra pneumonia, dengan seluruh proses analisis dilakukan menggunakan Orange Data Mining. Hasil eksperimen menunjukkan bahwa kombinasi Inception V3 dan SVM memberikan kinerja terbaik dengan nilai Area Under Curve (AUC) sebesar 0,731, Classification Accuracy (CA) sebesar 0,835, F1-score sebesar 0,805, Precision sebesar 0,810, Recall sebesar 0,835, dan Matthews Correlation Coefficient (MCC) sebesar 0,321. Sementara itu, kombinasi SqueezeNet dan Logistic Regression menghasilkan CA sebesar 0,771, F1-score sebesar 0,751, dan MCC sebesar 0,118, menunjukkan performa yang cukup kompetitif meskipun masih berada di bawah Inception V3 dan SVM. Hasil penelitian menunjukkan bahwa kualitas feature embedding yang dihasilkan oleh model deep learning memiliki pengaruh yang signifikan terhadap performa klasifikasi. Integrasi transfer learning dan machine learning konvensional terbukti mampu meningkatkan akurasi deteksi pneumonia serta berpotensi mendukung pengembangan sistem diagnosis berbasis kecerdasan buatan yang efisien dan akurat.

**Keywords:** Pneumonia; Inception V3; SqueezeNet; Logistic Regression; SVM

**Abstract**—This study evaluates the integration of deep learning-based feature extraction with conventional machine learning algorithms for pneumonia disease classification from chest X-ray images. Two pre-trained models, Inception V3 and SqueezeNet, are used as feature extractors due to their ability to generate effective feature representations from medical images. Inception V3 was chosen because it is able to capture complex visual patterns, while SqueezeNet offers computational efficiency with a smaller number of parameters. Meanwhile, Logistic Regression and Support Vector Machine (SVM) are used as classification algorithms due to their ability to handle high-dimensional data extracted from deep learning features. The dataset used consists of two categories, namely normal images and pneumonia images, with the entire analysis process carried out using Orange Data Mining. The experimental results show that the combination of Inception V3 and SVM provides the best performance with an Area Under Curve (AUC) of 0.731, Classification Accuracy (CA) of 0.835, F1-score of 0.805, Precision of 0.810, Recall of 0.835, and Matthews Correlation Coefficient (MCC) of 0.321. Meanwhile, the combination of SqueezeNet and Logistic Regression produces a CA of 0.771, an F1-score of 0.751, and an MCC of 0.118, showing quite competitive performance although still below Inception V3 and SVM. The results show that the quality of feature embedding generated by the deep learning model has a significant influence on classification performance. The integration of transfer learning and conventional machine learning has been proven to improve the accuracy of pneumonia detection and has the potential to support the development of an efficient and accurate artificial intelligence-based diagnostic system.

**Keywords:** Pneumonia; Inception V3; SqueezeNet; Logistic Regression; SVM

## 1. PENDAHULUAN

Pneumonia merupakan salah satu penyakit infeksi pada sistem pernapasan yang disebabkan oleh bakteri, virus, maupun jamur yang menyerang jaringan paru-paru dan mengakibatkan peradangan pada alveoli sehingga mengganggu proses pertukaran oksigen dalam tubuh. Penyakit ini masih menjadi salah satu penyebab utama morbiditas dan mortalitas di dunia, khususnya pada kelompok anak-anak dan lanjut usia. Diagnosis pneumonia secara dini sangat penting untuk meningkatkan peluang keberhasilan pengobatan dan menurunkan risiko komplikasi yang lebih serius. Salah satu metode diagnosis yang umum digunakan adalah analisis citra chest X-ray, karena mampu memberikan informasi visual mengenai kondisi paru-paru secara cepat dan relatif murah dibandingkan metode pencitraan lainnya. Perkembangan teknologi kecerdasan buatan (Artificial Intelligence/AI), khususnya deep learning dan machine learning, telah memberikan kontribusi yang signifikan dalam bidang analisis citra medis. Berbagai penelitian menunjukkan bahwa pendekatan berbasis Convolutional Neural Network (CNN) memiliki kemampuan yang sangat baik dalam mengenali pola visual kompleks pada citra medis, termasuk untuk mendeteksi penyakit pneumonia dari citra chest X-ray [1], [2]. CNN mampu melakukan ekstraksi fitur secara otomatis sehingga menghasilkan performa yang tinggi dalam berbagai tugas klasifikasi citra medis [3]. Selain model deep learning yang dilatih secara end-to-end, pendekatan transfer learning menggunakan model pra-latih juga semakin banyak digunakan karena mampu mengurangi kebutuhan data latih dan sumber daya komputasi yang besar [4].

Beberapa penelitian terdahulu telah menunjukkan keberhasilan penerapan deep learning dan transfer learning untuk klasifikasi pneumonia, termasuk penggunaan model CNN dan ensemble learning yang mampu meningkatkan akurasi deteksi pada citra chest X-ray anak-anak [5]. Maysanjaya [6] menggunakan CNN untuk mengklasifikasikan pneumonia pada citra X-ray paru-paru dengan dataset sebanyak 5.840 citra yang terdiri dari 1.575 citra normal dan 4.265 citra pneumonia. Hasil penelitian tersebut menunjukkan rata-rata akurasi sebesar 89,58%. Penelitian lain oleh Ekananda



dan Riminarsih [7] menggunakan arsitektur VGG16 dan memperoleh akurasi pelatihan sebesar 97,16% serta akurasi pengujian sebesar 88,46%. Selain itu, Bakti dan Firdaus [8] menerapkan arsitektur InceptionResNet-V2 untuk klasifikasi citra chest X-ray dan berhasil mencapai akurasi sebesar 98% pada klasifikasi beberapa kategori penyakit paru. Hasil-hasil tersebut menunjukkan bahwa model deep learning memiliki kemampuan yang sangat baik dalam mendeteksi pneumonia berdasarkan citra medis. Meskipun demikian, sebagian besar penelitian sebelumnya masih berfokus pada pendekatan deep learning end-to-end yang membutuhkan sumber daya komputasi relatif besar, waktu pelatihan yang panjang, serta proses implementasi yang lebih kompleks. Selain itu, kinerja model klasifikasi sering mengalami penurunan ketika menghadapi distribusi data yang tidak seimbang (imbalanced dataset), yang merupakan kondisi umum pada data medis [9], [10]. Di sisi lain, penelitian yang mengombinasikan feature extraction berbasis deep learning dengan algoritma machine learning konvensional masih relatif terbatas, khususnya pada platform visual data mining yang tidak memerlukan kemampuan pemrograman tingkat lanjut.

Dalam konteks tersebut, Orange Data Mining menjadi salah satu platform yang menarik untuk digunakan karena menyediakan lingkungan visual yang memungkinkan implementasi berbagai teknik analisis data secara lebih sederhana dan mudah dipahami [11], [12]. Orange memungkinkan integrasi antara model deep learning sebagai feature extractor dengan algoritma machine learning konvensional seperti Logistic Regression dan Support Vector Machine (SVM), sehingga dapat digunakan untuk membangun sistem klasifikasi yang efisien tanpa memerlukan proses pengembangan perangkat lunak yang kompleks.

Penelitian ini mengusulkan pendekatan klasifikasi pneumonia dengan memanfaatkan model pra-latih Inception V3 dan SqueezeNet sebagai feature extractor. Inception V3 dipilih karena memiliki kemampuan yang baik dalam menangkap pola visual yang kompleks melalui arsitektur multi-skala yang efisien [13], sedangkan *SqueezeNet* dipilih karena mampu menghasilkan performa yang kompetitif dengan jumlah parameter yang jauh lebih sedikit sehingga lebih ringan secara komputasi [14]. Fitur yang dihasilkan oleh kedua model tersebut kemudian diklasifikasikan menggunakan Logistic Regression dan Support Vector Machine (SVM), yang dikenal memiliki kemampuan yang baik dalam menangani data berdimensi tinggi hasil ekstraksi fitur deep learning [1], [15] [16].

Berdasarkan kajian penelitian terdahulu, masih terdapat kesenjangan penelitian (*research gap*) terkait evaluasi efektivitas kombinasi model transfer learning sebagai ekstraktor fitur dengan algoritma machine learning konvensional untuk klasifikasi pneumonia pada lingkungan visual data mining. Oleh karena itu, penelitian ini bertujuan untuk menganalisis dan membandingkan kinerja kombinasi Inception V3 dan SqueezeNet dengan Logistic Regression serta Support Vector Machine (SVM) dalam klasifikasi penyakit pneumonia berdasarkan citra chest X-ray menggunakan Orange Data Mining.

Kontribusi utama penelitian ini adalah: (1) mengevaluasi efektivitas model Inception V3 dan SqueezeNet sebagai ekstraktor fitur pada citra pneumonia, (2) membandingkan performa Logistic Regression dan SVM sebagai algoritma klasifikasi terhadap fitur yang dihasilkan model deep learning, serta (3) menyediakan kerangka kerja klasifikasi pneumonia yang mudah diimplementasikan menggunakan Orange Data Mining tanpa memerlukan kemampuan pemrograman yang kompleks. Hasil penelitian diharapkan dapat memberikan kontribusi terhadap pengembangan sistem diagnosis pneumonia berbasis kecerdasan buatan yang lebih efisien, akurat, dan mudah diterapkan pada berbagai lingkungan penelitian maupun layanan kesehatan.

## 2. METODOLOGI PENELITIAN

### 2.1 Dataset Penelitian

Penelitian ini menggunakan dataset citra chest X-ray yang terdiri atas dua kategori, yaitu citra normal dan citra pneumonia. Dataset berjumlah 109 citra, yang terdiri dari 89 citra normal dan 20 citra pneumonia. Citra normal berasal dari individu sehat, sedangkan citra pneumonia berasal dari pasien yang terdiagnosis pneumonia berdasarkan pemeriksaan medis. Dataset ini digunakan sebagai dasar dalam proses ekstraksi fitur dan klasifikasi untuk membedakan kondisi paru-paru normal dan pneumonia. Gambar 1 menunjukkan contoh citra chest X-ray normal, sedangkan Gambar 2 menunjukkan contoh citra chest X-ray pneumonia.




Gambar 1. X-ray paru-paru normal



Gambar 2. X-ray paru-paru Pneumonia

### 2.2 Tahapan Penelitian

Penelitian ini dilakukan melalui beberapa tahapan utama yang meliputi studi literatur, preprocessing data, ekstraksi fitur, klasifikasi, serta evaluasi hasil. Alur penelitian secara keseluruhan ditunjukkan pada Gambar 3.



**Gambar 3.** Diagram Alur Proses Klasifikasi Pneumonia

Gambar 3 menunjukkan tahapan penelitian yang dimulai dari studi literatur. Data kemudian melalui tahap preprocessing berupa konversi grayscale, normalisasi, dan augmentasi citra. Selanjutnya dilakukan ekstraksi fitur menggunakan model deep learning Inception V3 dan SqueezeNet melalui widget Image Embedding pada Orange Data Mining. Fitur yang dihasilkan kemudian digunakan sebagai masukan bagi algoritma Logistic Regression dan Support Vector Machine (SVM) untuk proses klasifikasi pneumonia. Kinerja setiap kombinasi model dievaluasi menggunakan metrik AUC, Accuracy, Precision, Recall, F1-Score, dan MCC untuk mengetahui performa masing-masing model dalam klasifikasi pneumonia

### 2.2.1 Studi Literatur

Tahap awal penelitian dilakukan melalui studi literatur terhadap berbagai penelitian yang berkaitan dengan klasifikasi pneumonia menggunakan metode deep learning dan machine learning. Literatur yang dikaji mencakup penggunaan model transfer learning seperti Inception V3, ResNet50, dan SqueezeNet, serta algoritma klasifikasi seperti Logistic Regression, Support Vector Machine (SVM), dan K-Nearest Neighbor (KNN). Studi literatur bertujuan untuk mengidentifikasi kelebihan dan kekurangan masing-masing metode serta menemukan research gap yang menjadi dasar penelitian ini [17], [18].

### 2.2.2 Preprocessing Data

Tahap preprocessing dilakukan untuk meningkatkan kualitas citra sebelum proses ekstraksi fitur. Seluruh citra chest X-ray dikonversi ke format grayscale untuk menonjolkan struktur anatomi paru-paru dan mengurangi kompleksitas data. Selanjutnya dilakukan normalisasi intensitas citra untuk menghasilkan distribusi piksel yang lebih seragam. Untuk meningkatkan variasi data dan mengurangi risiko overfitting, dilakukan data augmentation berupa rotasi, horizontal flipping, dan penyesuaian kontras (contrast adjustment). Tahapan ini bertujuan meningkatkan kemampuan generalisasi model dalam mengenali pola pneumonia pada berbagai kondisi citra [19].

### 2.2.3 Ekstraksi Fitur Menggunakan Inception V3 dan SqueezeNet

Ekstraksi fitur dilakukan menggunakan dua model deep learning pra-latih, yaitu Inception V3 dan SqueezeNet. Kedua model digunakan sebagai feature extractor untuk menghasilkan representasi fitur yang lebih informatif dari citra chest X-ray. Inception V3 merupakan arsitektur Convolutional Neural Network (CNN) yang menggunakan konsep inception module untuk menangkap informasi visual pada berbagai skala secara efisien. Model ini dikenal memiliki kemampuan yang baik dalam mengekstraksi fitur kompleks pada citra medis [13]. Sementara itu, SqueezeNet merupakan model CNN yang dirancang untuk menghasilkan performa yang kompetitif dengan jumlah parameter yang jauh lebih sedikit dibandingkan model CNN konvensional. Arsitektur ini memungkinkan proses ekstraksi fitur yang lebih ringan dan efisien tanpa mengurangi kualitas representasi fitur secara signifikan [3], [14]. Proses ekstraksi fitur dilakukan melalui widget Image Embedding pada Orange Data Mining sehingga setiap citra dikonversi menjadi vektor fitur yang selanjutnya digunakan pada tahap klasifikasi.

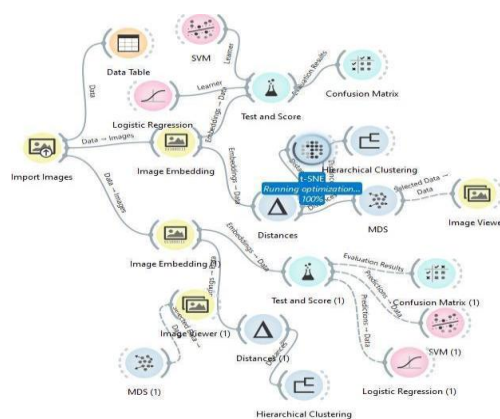
### 2.2.4 Klasifikasi Menggunakan Logistic Regression dan SVM

Fitur hasil ekstraksi dari Inception V3 dan SqueezeNet kemudian digunakan sebagai masukan bagi algoritma klasifikasi. Algoritma pertama yang digunakan adalah Logistic Regression, yaitu metode klasifikasi statistik yang mampu memodelkan probabilitas keanggotaan suatu kelas berdasarkan hubungan antara fitur dan label data. Logistic Regression

dipilih karena mampu bekerja dengan baik pada data berdimensi tinggi hasil ekstraksi fitur deep learning. Algoritma kedua adalah Support Vector Machine (SVM), yang bekerja dengan mencari hyperplane optimal untuk memisahkan data dari kelas yang berbeda. SVM dikenal memiliki kemampuan yang baik dalam menangani permasalahan klasifikasi pada data yang kompleks dan berdimensi tinggi [1], [15]. Kedua algoritma diterapkan pada fitur hasil ekstraksi Inception V3 dan SqueezeNet untuk mengetahui kombinasi model yang menghasilkan performa terbaik dalam klasifikasi pneumonia.

### 2.2.5 Evaluasi Kinerja Model

Evaluasi kinerja dilakukan menggunakan metode cross-validation yang tersedia pada platform Orange Data Mining. Kinerja model diukur menggunakan beberapa metrik evaluasi, yaitu Area Under Curve (AUC), Classification Accuracy (CA), Precision, Recall, F1-Score, dan Matthews Correlation Coefficient (MCC). Selain evaluasi kuantitatif, dilakukan pula visualisasi fitur menggunakan Multidimensional Scaling (MDS). Visualisasi ini digunakan untuk menggambarkan hubungan kedekatan antar data berdasarkan fitur yang dihasilkan oleh model deep learning, sehingga dapat memberikan gambaran mengenai tingkat separasi antara kelas normal dan pneumonia. Seluruh proses penelitian mulai dari preprocessing, ekstraksi fitur, klasifikasi, hingga evaluasi dilakukan menggunakan platform Orange Data Mining sebagaimana ditunjukkan pada Gambar 4.



Gambar 4. Proses Data Orange

## 3. HASIL DAN PEMBAHASAN

### 3.1 Hasil Preprocessing Data

Tahap awal penelitian dilakukan dengan mempersiapkan dataset citra chest X-ray yang terdiri atas 89 citra normal dan 20 citra pneumonia. Seluruh citra terlebih dahulu melalui proses preprocessing untuk meningkatkan kualitas data sebelum dilakukan ekstraksi fitur. Pada tahap ini citra dikonversi ke format grayscale untuk menyederhanakan representasi data dan menonjolkan struktur jaringan paru-paru. Selanjutnya dilakukan normalisasi intensitas piksel untuk mengurangi variasi pencahayaan antar citra. Untuk meningkatkan kemampuan generalisasi model, diterapkan teknik data augmentation berupa rotasi, horizontal flipping, dan penyesuaian kontras. Proses ini menghasilkan variasi data yang lebih beragam sehingga model dapat mengenali karakteristik pneumonia pada berbagai kondisi citra. Hasil preprocessing menunjukkan bahwa struktur anatomi paru-paru menjadi lebih jelas dan konsisten sehingga lebih siap untuk diproses pada tahap ekstraksi fitur.

### 3.2 Hasil Ekstraksi Fitur Menggunakan Inception V3 dan SqueezeNet

Setelah preprocessing selesai dilakukan, citra diproses menggunakan widget Image Embedding pada Orange Data Mining. Pada tahap ini digunakan dua model deep learning pra-latih yaitu Inception V3 dan SqueezeNet. Inception V3 digunakan karena memiliki kemampuan menangkap pola visual kompleks melalui kombinasi beberapa ukuran filter dalam satu modul. Model ini menghasilkan representasi fitur yang kaya sehingga mampu membedakan karakteristik paru-paru normal dan pneumonia secara lebih detail.

Sementara itu, SqueezeNet digunakan sebagai alternatif model ringan yang memiliki jumlah parameter lebih sedikit. Meskipun ukuran model lebih kecil, SqueezeNet tetap mampu menghasilkan representasi fitur yang relevan untuk proses klasifikasi. Output dari tahap ini berupa vektor fitur (feature embedding) yang merepresentasikan karakteristik setiap citra. Feature embedding tersebut kemudian digunakan sebagai masukan pada tahap klasifikasi menggunakan Logistic Regression dan SVM.

### 3.3 Hasil Klasifikasi Menggunakan Logistic Regression

Tahap klasifikasi pertama dilakukan menggunakan Logistic Regression. Algoritma ini memanfaatkan feature embedding yang dihasilkan oleh Inception V3 dan SqueezeNet untuk memprediksi kategori citra, yaitu normal atau pneumonia. Pada kombinasi Inception V3 dan Logistic Regression diperoleh nilai AUC sebesar 0,760, Classification Accuracy (CA)



sebesar 0,817, Precision sebesar 0,667, Recall sebesar 0,817, F1-score sebesar 0,734, dan MCC sebesar 0,000. Sementara itu, kombinasi SqueezeNet dan Logistic Regression menghasilkan nilai AUC sebesar 0,687, Classification Accuracy (CA) sebesar 0,817, Precision sebesar 0,667, Recall sebesar 0,817, F1-score sebesar 0,734, dan MCC sebesar 0,000. Hasil tersebut menunjukkan bahwa Logistic Regression mampu memanfaatkan feature embedding yang dihasilkan oleh kedua model deep learning untuk melakukan klasifikasi citra pneumonia. Meskipun nilai akurasi yang dihasilkan kedua kombinasi relatif sama, feature embedding dari Inception V3 menunjukkan kemampuan yang lebih baik dalam menghasilkan area under curve (AUC) yang lebih tinggi dibandingkan SqueezeNet, sehingga memiliki kemampuan diskriminasi kelas yang lebih baik.

### 3.4 Hasil Klasifikasi Menggunakan Support Vector Machine (SVM)

Selain Logistic Regression, penelitian ini juga menggunakan Support Vector Machine (SVM) sebagai metode klasifikasi. Pada kombinasi Inception V3 dan SVM diperoleh nilai AUC sebesar 0,731, Classification Accuracy sebesar 0,835, Precision sebesar 0,810, Recall sebesar 0,835, F1-score sebesar 0,805, dan MCC sebesar 0,321. Sedangkan kombinasi SqueezeNet dan SVM menghasilkan nilai AUC sebesar 0,713, Classification Accuracy sebesar 0,771, Precision sebesar 0,737, Recall sebesar 0,771, F1-score sebesar 0,751, dan MCC sebesar 0,118. Hasil ini menunjukkan bahwa SVM mampu memanfaatkan feature embedding hasil ekstraksi deep learning dengan baik, terutama pada kombinasi Inception V3 yang menghasilkan performa terbaik dibandingkan seluruh model yang diuji.

### 3.5 Implementasi Model dan Proses Klasifikasi

Setelah seluruh citra chest X-ray melalui tahap preprocessing dan ekstraksi fitur, data kemudian diproses menggunakan platform Orange Data Mining. Tahap implementasi dimulai dengan memasukkan dataset citra ke widget Image Embedding untuk menghasilkan feature embedding menggunakan model Inception V3 dan SqueezeNet. Setiap citra direpresentasikan dalam bentuk vektor numerik berdimensi tinggi yang mengandung informasi visual penting mengenai karakteristik paru-paru. Feature embedding yang dihasilkan selanjutnya dihubungkan ke widget Test and Score untuk dilakukan evaluasi menggunakan dua algoritma klasifikasi, yaitu Logistic Regression dan Support Vector Machine (SVM). Pada penelitian ini digunakan metode validasi silang (cross validation) yang bertujuan untuk mengukur kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya.

Pada algoritma Logistic Regression, proses klasifikasi dilakukan dengan menghitung probabilitas suatu citra termasuk ke dalam kelas normal atau pneumonia berdasarkan kombinasi bobot fitur yang dihasilkan oleh model deep learning. Sementara itu, algoritma SVM bekerja dengan mencari hyperplane optimal yang mampu memisahkan kedua kelas dengan margin maksimum pada ruang fitur yang terbentuk. Selama proses evaluasi, setiap model menghasilkan nilai prediksi yang kemudian dibandingkan dengan label sebenarnya. Hasil perbandingan tersebut digunakan untuk menghitung berbagai metrik evaluasi, yaitu Area Under Curve (AUC), Classification Accuracy (CA), Precision, Recall, F1-score, dan Matthews Correlation Coefficient (MCC). Nilai-nilai inilah yang digunakan sebagai dasar untuk menentukan model terbaik dalam klasifikasi pneumonia.

### 3.6 Perbandingan Kinerja Model

Tabel 1 menunjukkan perbandingan performa seluruh kombinasi model yang digunakan pada penelitian ini.

**Tabel 1.** Hasil Deep Learning

Model Deep Learning	Machine Learning	AUC	CA	F1	Precision	Recall	MCC
Inception V3	Logistic Regression	0.760	0.817	0.734	0.667	0.817	0.000
	SVM	0.731	0.835	0.805	0.810	0.835	0.321
SqueezeNet	Logistic Regression	0.687	0.817	0.734	0.667	0.817	0.000
	SVM	0.713	0.771	0.751	0.737	0.771	0.118

Berdasarkan hasil pengujian yang ditampilkan pada Tabel 1, terlihat bahwa setiap kombinasi model deep learning dan machine learning menghasilkan performa yang berbeda dalam mengklasifikasikan citra chest X-ray ke dalam kategori normal dan pneumonia. Perbedaan performa ini menunjukkan bahwa kualitas feature embedding yang dihasilkan oleh model deep learning memiliki pengaruh yang signifikan terhadap keberhasilan proses klasifikasi pada tahap berikutnya. Kombinasi Inception V3 dan SVM menghasilkan performa terbaik dibandingkan seluruh kombinasi model yang diuji. Model ini memperoleh nilai Classification Accuracy (CA) sebesar 0,835, F1-score sebesar 0,805, Precision sebesar 0,810, Recall sebesar 0,835, serta Matthews Correlation Coefficient (MCC) sebesar 0,321. Tingginya nilai akurasi menunjukkan bahwa sebagian besar citra berhasil diklasifikasikan dengan benar, sedangkan nilai F1-score yang tinggi menunjukkan keseimbangan yang baik antara precision dan recall. Nilai MCC yang lebih tinggi dibandingkan model lain mengindikasikan bahwa kemampuan model dalam membedakan kelas normal dan pneumonia relatif lebih baik, bahkan pada kondisi distribusi data yang tidak seimbang.

Performa yang baik pada kombinasi Inception V3 dan SVM dapat dijelaskan dari karakteristik kedua metode tersebut. Inception V3 memiliki arsitektur yang mampu menangkap informasi visual pada berbagai skala melalui penggunaan inception module. Mekanisme ini memungkinkan model untuk mengekstraksi pola-pola kompleks pada citra chest X-ray, seperti keberadaan infiltrat, opasitas paru, maupun perubahan jaringan paru yang sering muncul pada kasus pneumonia. Setelah fitur-fitur tersebut diekstraksi, SVM bekerja dengan membangun hyperplane optimal yang

memisahkan dua kelas berdasarkan feature embedding yang dihasilkan. Ketika fitur yang diberikan memiliki tingkat separabilitas yang tinggi, SVM dapat membentuk batas keputusan yang lebih efektif sehingga menghasilkan akurasi klasifikasi yang lebih baik. Sebaliknya, kombinasi SqueezeNet dan Logistic Regression menghasilkan nilai CA sebesar 0,771, F1-score sebesar 0,751, dan MCC sebesar 0,118. Walaupun performanya berada di bawah Inception V3, hasil tersebut tetap menunjukkan bahwa SqueezeNet mampu menghasilkan representasi fitur yang cukup informatif untuk membedakan citra normal dan pneumonia. Keunggulan utama SqueezeNet terletak pada jumlah parameter yang jauh lebih sedikit dibandingkan model deep learning lainnya sehingga proses ekstraksi fitur dapat dilakukan dengan lebih cepat dan efisien. Dengan demikian, model ini berpotensi digunakan pada lingkungan komputasi dengan sumber daya terbatas.


Secara umum, kombinasi yang menggunakan feature embedding dari Inception V3 menghasilkan performa klasifikasi yang lebih baik dibandingkan kombinasi yang menggunakan feature embedding dari SqueezeNet, terutama pada metrik Classification Accuracy, F1-score, dan MCC. Hasil ini menunjukkan bahwa Inception V3 mampu menghasilkan representasi fitur yang lebih diskriminatif untuk membedakan citra normal dan pneumonia. Feature embedding yang lebih kaya memungkinkan algoritma klasifikasi mengenali karakteristik visual yang membedakan kondisi paru-paru normal dan pneumonia secara lebih akurat. Dengan kata lain, keberhasilan proses klasifikasi tidak hanya ditentukan oleh algoritma machine learning yang digunakan, tetapi juga sangat dipengaruhi oleh kualitas representasi fitur yang dihasilkan pada tahap ekstraksi.

Hasil penelitian menunjukkan bahwa model transfer learning mampu memanfaatkan pengetahuan yang telah dipelajari dari dataset berskala besar untuk meningkatkan performa klasifikasi citra chest X-ray tanpa memerlukan proses pelatihan dari awal. Pendekatan tersebut memungkinkan pengurangan kebutuhan data latih sekaligus meningkatkan efisiensi komputasi [20]. Model tidak perlu dilatih ulang dari awal karena telah memanfaatkan pengetahuan yang diperoleh dari dataset berskala besar sebelumnya. Pendekatan ini memberikan keuntungan berupa efisiensi komputasi sekaligus tetap mampu menghasilkan performa klasifikasi yang kompetitif pada dataset yang relatif kecil.

### 3.7 Analisis Visualisasi MDS

Untuk memperoleh pemahaman yang lebih mendalam mengenai kualitas feature embedding yang dihasilkan oleh model deep learning, dilakukan visualisasi menggunakan Multidimensional Scaling (MDS). Teknik MDS digunakan untuk memproyeksikan data berdimensi tinggi ke dalam ruang dua dimensi sehingga hubungan kedekatan antar data dapat diamati secara visual. Semakin baik kualitas feature embedding yang dihasilkan, maka semakin jelas pula pemisahan antara kelompok data normal dan pneumonia pada visualisasi MDS.

#### 3.7.1 MDS Inception V3




**Gambar 5.** MDS Inception V3

Gambar 5 menunjukkan hasil visualisasi MDS berdasarkan feature embedding yang dihasilkan oleh Inception V3. Setiap titik pada grafik merepresentasikan satu citra chest X-ray, sedangkan warna menunjukkan kategori kelas yang dimiliki. Titik berwarna biru menunjukkan citra normal, sementara titik berwarna merah menunjukkan citra pneumonia.

Pada visualisasi terlihat bahwa sebagian besar data membentuk kelompok yang relatif terpisah berdasarkan kategorinya. Meskipun masih terdapat beberapa titik yang berada pada area tumpang tindih, pola distribusi secara keseluruhan menunjukkan adanya kecenderungan pemisahan yang cukup jelas antara kedua kelas. Hal ini mengindikasikan bahwa Inception V3 mampu mengekstraksi fitur-fitur yang relevan untuk membedakan karakteristik visual antara paru-paru normal dan paru-paru yang terinfeksi pneumonia. Kemampuan Inception V3 dalam menghasilkan pemisahan kelas yang lebih baik kemungkinan disebabkan oleh struktur arsitekturnya yang menggunakan berbagai ukuran filter secara simultan dalam satu modul. Pendekatan ini memungkinkan model menangkap informasi lokal maupun global secara bersamaan, sehingga variasi pola pneumonia dapat direpresentasikan dengan lebih baik. Oleh

karena itu, feature embedding yang dihasilkan memiliki tingkat separabilitas yang tinggi dan mendukung peningkatan performa klasifikasi pada tahap berikutnya.

Selain menunjukkan kualitas representasi fitur, visualisasi MDS juga memperlihatkan bahwa masih terdapat beberapa titik pneumonia yang berada dekat dengan kelompok normal. Kondisi ini menunjukkan adanya kemiripan karakteristik visual pada sebagian citra, terutama pada kasus pneumonia ringan atau citra dengan kualitas pencitraan yang kurang optimal. Faktor ini dapat menjadi salah satu penyebab kesalahan klasifikasi yang masih terjadi pada model.



**Gambar 6.** MDS SqueezeNet

### 3.7.2 MDS SqueezeNet

Gambar 6 menunjukkan hasil visualisasi MDS berdasarkan feature embedding yang dihasilkan oleh SqueezeNet. Berbeda dengan Inception V3, distribusi titik pada SqueezeNet terlihat lebih menyebar dan menunjukkan tingkat tumpang tindih yang lebih besar antara kelas normal dan pneumonia.

Pola tersebut mengindikasikan bahwa fitur yang dihasilkan oleh SqueezeNet belum mampu memisahkan kedua kategori secara optimal. Beberapa titik dari kelas pneumonia berada sangat dekat dengan kelompok normal, sehingga batas antar kelas menjadi kurang jelas. Kondisi ini menyebabkan algoritma klasifikasi mengalami kesulitan dalam menentukan keputusan yang tepat pada beberapa sampel. Meskipun demikian, visualisasi MDS tetap menunjukkan adanya pola pengelompokan yang cukup baik. Hal ini menandakan bahwa SqueezeNet masih mampu menangkap karakteristik dasar dari citra chest X-ray. Namun karena jumlah parameter yang lebih sedikit dan struktur model yang lebih sederhana dibandingkan Inception V3, representasi fitur yang dihasilkan menjadi kurang kaya sehingga kemampuan pemisahan kelas juga menjadi lebih rendah.

Hasil visualisasi ini konsisten dengan hasil evaluasi kuantitatif yang diperoleh sebelumnya. Model yang menghasilkan pemisahan kelas lebih jelas pada visualisasi MDS juga menunjukkan nilai akurasi, F1-score, dan MCC yang lebih tinggi. Dengan demikian, visualisasi MDS tidak hanya berfungsi sebagai alat eksplorasi data, tetapi juga sebagai bukti visual yang mendukung hasil evaluasi klasifikasi.

### 3.8 Pembahasan

Secara keseluruhan, penelitian ini menunjukkan bahwa integrasi antara deep learning sebagai feature extractor dan machine learning sebagai classifier merupakan pendekatan yang efektif untuk klasifikasi pneumonia berbasis citra chest X-ray. Pendekatan ini memungkinkan pemanfaatan kemampuan deep learning dalam mengekstraksi fitur visual yang kompleks tanpa memerlukan proses pelatihan model secara penuh, sehingga lebih efisien dari sisi komputasi. Hasil penelitian menunjukkan bahwa kualitas feature embedding memiliki pengaruh yang signifikan terhadap keberhasilan klasifikasi citra pneumonia. Hasil penelitian ini sejalan dengan penelitian sebelumnya yang menunjukkan bahwa arsitektur Inception V3 mampu menghasilkan representasi fitur yang lebih kaya pada citra medis karena memanfaatkan berbagai ukuran kernel secara simultan. Kemampuan tersebut memungkinkan model menangkap pola infiltrasi dan opasitas paru yang menjadi indikator utama pneumonia sehingga meningkatkan performa klasifikasi. Sementara itu, SVM menunjukkan kemampuan yang baik dalam memanfaatkan fitur berdimensi tinggi untuk membangun batas keputusan yang optimal. Temuan ini memperlihatkan bahwa kombinasi Inception V3 dan SVM merupakan pendekatan yang paling efektif pada dataset yang digunakan dalam penelitian ini. Selain menghasilkan akurasi tertinggi, kombinasi tersebut juga menghasilkan nilai MCC yang lebih baik sehingga menunjukkan kemampuan klasifikasi yang lebih seimbang. Hasil ini memperkuat temuan penelitian sebelumnya yang menyatakan bahwa transfer learning dan machine learning konvensional dapat saling melengkapi dalam menghasilkan sistem klasifikasi citra medis yang akurat dan efisien.

Pendekatan yang diusulkan tidak hanya mampu meningkatkan performa klasifikasi pneumonia, tetapi juga memberikan alternatif implementasi yang lebih ringan dan mudah diterapkan melalui platform Orange Data Mining.



Pendekatan ini berpotensi dikembangkan lebih lanjut pada dataset yang lebih besar maupun pada klasifikasi penyakit paru lainnya untuk mendukung sistem diagnosis berbasis kecerdasan buatan di bidang kesehatan.

#### 4. KESIMPULAN

Penelitian ini menunjukkan bahwa integrasi antara ekstraksi fitur berbasis deep learning dan algoritma klasifikasi machine learning konvensional mampu menghasilkan performa yang baik dalam klasifikasi penyakit pneumonia berdasarkan citra chest X-ray. Dengan memanfaatkan feature embedding yang dihasilkan oleh model pra-latih Inception V3 dan SqueezeNet, kemudian dikombinasikan dengan algoritma Logistic Regression dan Support Vector Machine (SVM), penelitian ini berhasil membangun sistem klasifikasi yang efektif menggunakan platform Orange Data Mining. Berdasarkan hasil pengujian, kombinasi Inception V3 dan SVM menghasilkan performa terbaik dibandingkan seluruh model yang diuji, dengan nilai Classification Accuracy (CA) sebesar 0,835, F1-score sebesar 0,805, Precision sebesar 0,810, Recall sebesar 0,835, dan Matthews Correlation Coefficient (MCC) sebesar 0,321. Hasil tersebut menunjukkan bahwa feature embedding yang dihasilkan oleh Inception V3 memiliki kemampuan yang lebih baik dalam merepresentasikan karakteristik visual citra pneumonia sehingga mampu meningkatkan kinerja klasifikasi. Sementara itu, SqueezeNet juga menunjukkan performa yang cukup baik meskipun memiliki arsitektur yang lebih ringan dan jumlah parameter yang lebih sedikit. Hasil ini menunjukkan bahwa model dengan kompleksitas yang lebih rendah tetap mampu menghasilkan representasi fitur yang relevan untuk proses klasifikasi citra medis. Visualisasi menggunakan Multidimensional Scaling (MDS) turut mendukung hasil evaluasi kuantitatif dengan memperlihatkan bahwa feature embedding dari Inception V3 menghasilkan pemisahan kelas yang lebih jelas dibandingkan SqueezeNet. Secara keseluruhan, penelitian ini membuktikan bahwa kombinasi transfer learning sebagai feature extractor dan machine learning sebagai classifier dapat menjadi pendekatan yang efektif untuk klasifikasi pneumonia pada dataset berukuran relatif kecil. Untuk penelitian selanjutnya, disarankan penggunaan dataset yang lebih besar dan lebih seimbang, eksplorasi arsitektur deep learning lainnya, serta penerapan teknik optimasi fitur guna meningkatkan kemampuan generalisasi model dan mengurangi tumpang tindih antar kelas.

#### REFERENCES

- [1] M. Mujahid *et al.*, "Pneumonia Classification from X-ray Images with Inception-V3 and Convolutional Neural Network," *Diagnostic*, vol. 12, no. 1280, pp. 1–16, 2022.
- [2] A. Manickam, J. Jiang, Y. Zhou, A. Sagar, R. Soundrapandian, and R. D. Jackson, "Automated pneumonia detection on chest X-ray images : A deep learning approach with different optimizers and transfer learning architectures," *Measurement*, vol. 184, no. July, p. 109953, 2021, doi: 10.1016/j.measurement.2021.109953.
- [3] K. E. L. Asnaoui, Y. Chawki, and A. Idri, "Automated Methods for Detection and Classification Pneumonia based on X-Ray Images Using Deep Learning," *Artif. Intell. Blockchain Futur. Cybersecurity Appl.*, vol. 5, p. 284, 2021, doi: 10.1007/978-3-030-74575-2\_14.
- [4] D. R. Rochmawati and L. Maryani, "Deep Learning-Based ResNet-50 Transfer Learning Approaches for Pneumonia Detection from Chest X-Ray Images : With and Without Fine-Tuning," *Indones. J. Heal. Res. Dev.*, vol. 3, no. 3, pp. 146–153, 2025, doi: <https://doi.org/10.58723/ijhrd.v3i3.507>.
- [5] E. Bachtiar, A. H. Dinnillah, and Y. Rianto, "Systematic Literature Review of Transfer Learning for Pneumonia Classification in Chest X-Rays," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 6, no. 2, pp. 577–590, 2026, doi: <https://doi.org/10.57152/malcom.v6i2.2470>.
- [6] I. M. D. Maysanjaya, "Klasifikasi Pneumonia pada Citra X-rays Paru-paru dengan Convolutional Neural Network," *J. Nas. Tek. Elektro dan Teknol. Inf.*, vol. 9, no. 2, p. 190, 2020, [Online]. Available: <https://garuda.kemdikbud.go.id/documents/detail/2807288>
- [7] A. A. Kurniawan, H. D. Baharna, and R. M. Suri, "Model deep learning untuk deteksi pneumonia studi eksperimen menggunakan cnn arsitektur vgg16," *J. Inform. Medis*, vol. 3, no. 2, pp. 6–11, 2025, doi: 10.52060/im.v3i2.3847.
- [8] I. Bakti and M. Firdaus, "Arsitektur Convolutional Neural Network InceptionResNet-V2 Untuk Pengelompokan Pneumonia Chest X-Ray," *JUKOMTEK (Jurnal Komput. dan Teknol.)*, vol. 02, no. 01, pp. 35–42, 2023, doi: 10.58290/jukomtek.
- [9] X. Xue *et al.*, "Design and Analysis of a Deep Learning Ensemble Framework Model for the Detection of COVID-19 and Pneumonia Using Large-Scale CT Scan and X-ray Image Datasets," *Bioeng. Artic.*, vol. 10, no. 363, p. 21, 2023, doi: <https://doi.org/10.3390/bioengineering10030363>.
- [10] M. W. Njoroge, S. O. Abuodha, E. K. Kabando, and K. O. Achieng, "Modelling of Restrained Shrinkage Stresses in Mortar using Artificial Neural Networks," *Int. Res. J. Multidiscip. Technovation*, vol. 6, no. 5, pp. 40–60, 2024, doi: <https://doi.org/10.54392/irjmt2454>.
- [11] J. Demšar and Blaz Zupan, "Hands-on training about data clustering with orange data mining toolbox," *PLoS Comput. Biol.*, vol. 12, no. 18, pp. 1–9, 2024, doi: 10.1371/journal.pcbi.1012574.
- [12] E. Korot *et al.*, "Code-free deep learning for multi-modality medical image classification," *Nat. Mach. Intell.*, vol. 3, no. April, p. 298, 2021, doi: 10.1038/s42256-021-00305-2.
- [13] X. Zhao, L. Wang, Y. Zhang, X. Han, M. Deveci, and M. Parmar, *A review of convolutional neural networks in computer vision*, vol. 57, no. 4. Springer Netherlands, 2024. doi: 10.1007/s10462-024-10721-6.
- [14] Y. Chandola, V. Uniyal, and Y. Bachheti, "Efficient Chest X-Ray Feature Extraction and Feature Fusion for Pneumonia Detection Using Lightweight Pretrained Deep Learning Models," *Heal. CARE Res. J. (HCRJ)*, vol. 30, no. 6, 2025, doi: <https://doi.org/10.1101/2025.06.28.25330459>.
- [15] M. Mamalakis *et al.*, "DenResCov-19: A deep transfer learning network for robust automatic classification of COVID-19, pneumonia, and tuberculosis from X-rays Michail," *Comput. Med. Imaging Graph.*, vol. 94, no. September, p. 102008, 2021,



- doi: 10.1016/j.compmedimag.2021.102008.
- [16] A. Mabrouk, R. P. D. Redondo, A. Dahou, M. A. Elaziz, and M. Kayed, "Pneumonia Detection on chest X-ray images Using Ensemble of Deep Convolutional Neural Networks," *Appl. Sci.*, vol. 12, no. 13, pp. 1–10, 2022, doi: <https://doi.org/10.3390/app12136448>.
- [17] G. A. Sandag, T. J. Mulalinda, G. A. M. Susanto, and S. R. Pungus, "Advanced pneumonia classification using transfer learning on chest X-ray data with EfficientNet and ResNet," *TELKOMNIKA Telecommun. Comput. Electron. Control*, vol. 23, no. 5, pp. 1304–1313, 2025, doi: 10.12928/TELKOMNIKA.v23i5.26387.
- [18] M. Neshat, M. Ahmed, H. Askari, M. Thilakaratne, and S. Mirjalili, "Hybrid Inception Architecture with Residual Connection : Fine-tuned Inception-ResNet Deep Learning Model for Lung Inflammation Diagnosis from Chest Radiographs," *Procedia Comput. Sci.*, vol. 235, p. 1850, 2024, doi: <https://doi.org/10.1016/j.procs.2024.04.175>.
- [19] T. Rahman *et al.*, "Transfer Learning with Deep Convolutional Neural Network (CNN) for Pneumonia Detection Using Chest X-ray," *MDPI, J. app Sci.*, vol. 3233, no. 10, pp. 1–17, 2020, doi: 10.3390/app10093233.
- [20] A. Abbas, M. M. Abdelsamea, and M. M. Gaber, "Classification of COVID-19 in chest X-ray images using DeTraC deep convolutional neural network," *Appl. Intell.*, vol. 51, pp. 854–864, 2021, doi: <https://doi.org/10.1007/s10489-020-01829-7>.