

# Perbandingan Kinerja Algoritma Machine Learning dalam Klasifikasi Penyakit Fundus Menggunakan Citra Fundus Digital

Deny Kurniawan<sup>1</sup>, Dedi Triyanto<sup>2</sup>, Lita Sari Marita<sup>3</sup>, Ade christian<sup>4</sup>, Sumanto<sup>5\*</sup>

<sup>1,2</sup>Sistem Informasi, Universitas Bina Sarana Informatika, Indonesia

<sup>3,5</sup>Informatika, Universitas Bina Sarana Informatika, Indonesia

<sup>4</sup>Teknologi Informasi, Universitas Bina Sarana Informatika, Indonesia

<sup>1</sup>deny.kurniawan@bsi.ac.id, <sup>2</sup>dedi.triyanto@bsi.ac.id, <sup>3</sup>lita.lsm@bsi.ac.id,

<sup>4</sup>ade.adc@bsi.ac.id, <sup>5\*</sup>sumanto@bsi.ac.id

Submitted	Accepted	Publish
11-December-2025	30-December-2025	31-December-2025

**Abstrak:** Penyakit fundus mata seperti diabetic retinopathy, cataract, dan glaucoma merupakan penyebab utama gangguan penglihatan hingga kebutaan apabila tidak terdeteksi sejak dini. Diagnosis penyakit fundus secara konvensional masih sangat bergantung pada penilaian visual tenaga medis, yang berpotensi menimbulkan subjektivitas dan keterlambatan penanganan. Oleh karena itu, penelitian ini bertujuan untuk menerapkan dan membandingkan metode machine learning dalam mendeteksi penyakit fundus berdasarkan citra fundus digital serta menentukan algoritma dengan kinerja terbaik. Penelitian ini menggunakan dataset publik yang terdiri dari 600 citra fundus yang terbagi secara seimbang ke dalam empat kelas, yaitu Normal, Background Diabetic Retinopathy, Cataract, dan Glaucoma, dengan masing-masing kelas berjumlah 150 citra. Dataset dibagi menjadi data training dan data testing dengan rasio 80:20. Tiga algoritma machine learning yang digunakan adalah Support Vector Machine (SVM), K-Nearest Neighbors (KNN), dan Random Forest. Evaluasi kinerja model dilakukan menggunakan metrik akurasi, precision, recall, dan F1-score. Hasil penelitian menunjukkan bahwa seluruh model mampu mencapai tingkat akurasi di atas 80%, dengan SVM menghasilkan akurasi tertinggi sebesar 88,0%, diikuti oleh KNN sebesar 87,7% dan Random Forest sebesar 82,5%. Hasil ini menunjukkan bahwa metode machine learning, khususnya SVM, efektif digunakan dalam mendeteksi penyakit fundus dan berpotensi dikembangkan sebagai sistem pendukung diagnosis dini. Meskipun demikian, penelitian lanjutan masih diperlukan dengan dataset yang lebih besar dan beragam untuk meningkatkan kemampuan generalisasi model.


**Kata Kunci:** Penyakit fundus, machine learning, citra fundus, SVM, KNN, Random Forest

**Abstract:** Fundus diseases such as diabetic retinopathy, cataract, and glaucoma are among the leading causes of visual impairment and blindness if not detected at an early stage. Conventional fundus disease diagnosis still relies heavily on visual assessment by medical experts, which may lead to subjectivity and delayed treatment. Therefore, this study aims to apply and compare machine learning methods for fundus disease detection using digital fundus images in order to identify the most effective classification algorithm. This study utilizes a public dataset consisting of 600 fundus images evenly distributed into four classes, namely Normal, Background Diabetic Retinopathy,

Sumanto: \*Penulis Korespondensi



Copyright © 2025, Deny Kurniawan, Dedi Triyanto, Lita Sari Marita, Ade Christian, Sumanto.



*Cataract, and Glaucoma, with 150 images per class. The dataset is divided into training and testing sets using an 80:20 ratio. Three machine learning algorithms are implemented, including Support Vector Machine (SVM), K-Nearest Neighbors (KNN), and Random Forest. Model performance is evaluated using accuracy, precision, recall, and F1-score metrics. The experimental results show that all models achieve classification accuracy above 80%, indicating that machine learning approaches are effective for fundus disease detection. Among the evaluated methods, SVM achieves the highest accuracy of 88.0%, followed by KNN with 87.7% and Random Forest with 82.5%. These findings demonstrate that machine learning, particularly SVM, has strong potential to support early fundus disease diagnosis. However, further research using larger and more diverse datasets is recommended to improve model generalization and robustness.*

**Keywords:** *Fundus disease, machine learning, fundus image, SVM, KNN, Random Forest*

## 1. PENDAHULUAN

Deteksi dini penyakit fundus sangat penting untuk mencegah kehilangan penglihatan, karena kondisi okular ini sering kali muncul tanpa gejala yang nyata hingga kerusakan yang signifikan sudah terjadi. Penyakit fundus, yang meliputi Normal, Diabetic Retinopathy Latar Belakang (DR), Katarak, dan Glaukoma, merupakan penyebab kebutaan dan gangguan penglihatan yang cukup besar di seluruh dunia. Misalnya, Diabetic Retinopathy muncul akibat diabetes kronis dan mempengaruhi jutaan individu, sehingga diagnosis yang tepat waktu sangat penting untuk menghentikan atau membalikkan perkembangan penyakit tersebut [1], [2]. Demikian pula, kondisi seperti Glaukoma menyebabkan kehilangan penglihatan yang tidak dapat dipulihkan, menyoroti perlunya intervensi dini [3]. Saat ini, tes lapang visual dan tomography koherensi optik (OCT) memiliki peran penting dalam mendiagnosis penyakit ini, namun mereka menunjukkan variabilitas dalam sensitivitas dan spesifisitasnya [4]. Oleh karena itu, memanfaatkan teknik canggih seperti pembelajaran mesin untuk analisis gambar fundus retina dapat meningkatkan proses skrining, membuatnya lebih cepat dan akurat, yang pada akhirnya memperbaiki hasil bagi pasien [5], [6]. Selain itu, Katarak merupakan penyebab utama kebutaan, yang sering berkembang seiring waktu dan memerlukan intervensi bedah jika tidak teridentifikasi dengan cepat [7]. Saat ini, sebagian besar teknologi pencitraan tidak dapat mengatasi semua masalah yang dihadapi dalam diagnosis penyakit fundus. Dengan munculnya pembelajaran mesin dan penelitian terbaru, kita perlu mengeksplorasi bagaimana teknik ini dapat digunakan untuk menganalisis citra fundus secara lebih efektif. Pemanfaatan algoritma pembelajaran mesin dapat membantu dokter dalam mengidentifikasi penyakit lebih awal dan meminimalkan risiko kesalahan diagnosis [7].


Meskipun terdapat potensi menjanjikan dari teknologi pencitraan, terdapat tantangan inheren dalam deteksi otomatis penyakit fundus. Variabilitas dalam kualitas gambar sangat mempengaruhi kinerja algoritma deteksi; misalnya, kebisingan, perubahan pencahayaan, dan penghalang dapat menutupi fitur penting yang diperlukan untuk diagnosis yang akurat [7]. Selain itu, tumpang tindih fitur antara berbagai penyakit membuat klasifikasi menjadi rumit — sebuah tantangan yang disoroti oleh kesamaan diagnostik yang terlihat antara tahap-tahap diabetic retinopathy dan kondisi okular lainnya [8]. Sebagai akibatnya, sistem yang ada dapat melakukan klasifikasi yang salah, menyebabkan keterlambatan dalam diagnosis dan rencana pengobatan yang tidak sesuai, sehingga mempertegas kebutuhan untuk algoritma yang efektif dan mampu menangani kompleksitas ini [9].

*Machine Learning* (ML) memainkan peran penting dalam meningkatkan akurasi deteksi dan klasifikasi penyakit. Dalam konteks fotografi fundus, berbagai model pembelajaran mesin, termasuk *K-nearest neighbors* (KNN), *Support Vector Machines* (SVM), dan *Random Forest*

Sumanto: \*Penulis Korespondensi



Copyright © 2025, Deny Kurniawan, Dedi Triyanto, Lita Sari Marita, Ade Christian, Sumanto.



(RF), menyediakan teknik canggih untuk otomatisasi diagnosis. KNN, dengan ketergantungannya pada ukuran kedekatan, telah menunjukkan efektivitas pada fase klasifikasi awal [10]. Sebaliknya, SVM unggul dalam ruang dimensi tinggi, menjadikannya cocok untuk membedakan fitur-fitur subtil dalam gambar okular [11]. Sementara itu, Random Forest menggunakan prinsip pembelajaran ansambel, menawarkan ketahanan terhadap overfitting dan menangani data yang bising dengan efektif [12], [13]. Bersama-sama, model-model ini dapat memanfaatkan kompleksitas citra fundus retina untuk memfasilitasi identifikasi penyakit yang lebih awal dan terpercaya.

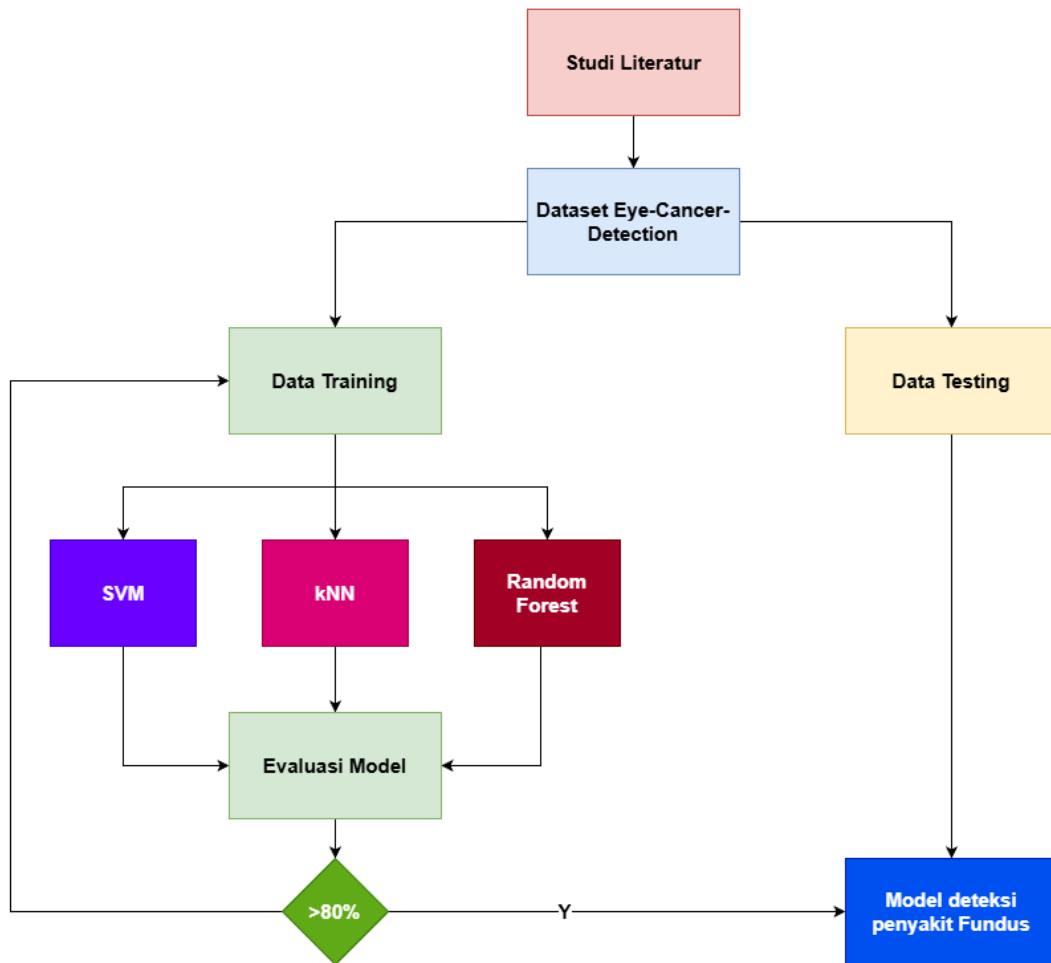
Tujuan utama dari perbandingan KNN, SVM, dan Random Forest untuk deteksi penyakit fundus terletak pada penentuan teknik paling efektif dalam menganalisis gambar retina. Setiap algoritma menawarkan keunggulan yang berbeda dalam hal akurasi, waktu pemrosesan, dan interpretabilitas, yang semuanya merupakan parameter kritis yang mempengaruhi aplikasi klinis. Studi menunjukkan bahwa meskipun kinerja masing-masing model mungkin bervariasi, pendekatan ansambel yang menggabungkan beberapa model dapat meningkatkan akurasi diagnostik [14]. Menganalisis algoritma ini membantu dalam mengoptimalkan sistem pencitraan di masa depan, memastikan bahwa praktisi dilengkapi dengan alat yang sesuai untuk deteksi dini [15].

Lebih jauh lagi, analisis komparatif ini bertujuan untuk memperdalam pemahaman tentang kekuatan dan keterbatasan yang melekat pada masing-masing algoritma dalam konteks oftalmologi. Misalnya, percobaan menunjukkan bahwa SVM mungkin lebih unggul dibandingkan KNN, terutama dalam tugas yang memerlukan interpretabilitas tinggi di dataset yang lebih kecil, sementara Random Forest mungkin unggul dalam set yang lebih besar dengan interaksi variabel yang kompleks [16], [17], [18]. Memahami dinamika ini sangat mendasar untuk mengembangkan sistem diagnostik yang handal dan akurat yang relevan dengan lanskap kesehatan yang terus berkembang. Penelitian ini berkontribusi dengan menyajikan analisis komparatif yang komprehensif terhadap kinerja algoritma KNN, SVM, dan Random Forest dalam klasifikasi multikelas penyakit fundus retina, meliputi kondisi normal, diabetic retinopathy, katarak, dan glaukoma. Kontribusi utama terletak pada evaluasi empiris masing-masing algoritma dalam menghadapi tantangan citra fundus yang kompleks, seperti variabilitas kualitas gambar dan tumpang tindih fitur antar penyakit. Hasil penelitian ini diharapkan dapat menjadi dasar pengembangan sistem pendukung keputusan klinis yang lebih akurat, efisien, dan andal untuk mendukung deteksi dini penyakit fundus dalam praktik oftalmologi.

## **2. METODE PENELITIAN**

Dalam penelitian ini, digunakan alur metodologi berbasis machine learning untuk mendeteksi penyakit fundus secara sistematis dan terstruktur. Alur tahapan penelitian tersebut disajikan pada Gambar 1, yang menggambarkan proses mulai dari studi literatur, penggunaan dataset publik, pembagian data training dan testing, penerapan metode SVM, KNN, dan Random Forest, hingga evaluasi model untuk memperoleh model deteksi penyakit fundus dengan tingkat akurasi yang ditetapkan.






**Gambar 1.** Tahapan Penelitian Komparasi Penyakit Fundus Dengan Machine Learning

### 1. Studi Literatur

Tahap awal penelitian diawali dengan studi literatur yang bertujuan untuk memperoleh landasan teoritis dan pemahaman komprehensif terkait deteksi penyakit fundus berbasis citra medis. Studi literatur dilakukan dengan menelaah berbagai jurnal ilmiah, prosiding konferensi, serta buku referensi yang membahas penyakit fundus mata seperti diabetic retinopathy, cataract, dan glaucoma, serta pendekatan komputasional yang digunakan dalam diagnosis penyakit tersebut. Selain itu, kajian literatur juga difokuskan pada penerapan metode machine learning dalam klasifikasi citra fundus, khususnya algoritma Support Vector Machine (SVM), K-Nearest Neighbors (KNN), dan Random Forest. Hasil dari tahap ini digunakan untuk mengidentifikasi permasalahan penelitian, menentukan metode yang relevan, serta merancang alur penelitian yang sistematis dan sesuai dengan tujuan penelitian.

### 2. Dataset

Pada tahap ini, penelitian menggunakan dataset publik citra fundus yang terdiri dari **600 data citra**, yang terbagi secara seimbang ke dalam **empat kelas**, yaitu **Normal, Background Diabetic Retinopathy, Cataract, dan Glaucoma**, dengan masing-masing kelas berjumlah **150 citra**. Distribusi data yang seimbang ini bertujuan untuk menghindari bias kelas (class imbalance) yang dapat memengaruhi performa model machine learning. Dataset publik dipilih karena telah melalui proses anotasi yang valid serta banyak



digunakan dalam penelitian sebelumnya, sehingga mendukung keterulangan (reproducibility) dan perbandingan hasil penelitian. Seluruh data citra kemudian diverifikasi untuk memastikan kesesuaian format, resolusi, dan label kelas sebelum digunakan pada tahap selanjutnya.

### **3. Pembagian Data Training dan Data Testing**

Dataset selanjutnya dibagi menjadi data training dan data testing. Dari total **600 citra fundus**, pembagian data dilakukan secara proporsional pada setiap kelas agar representasi data tetap seimbang. Sebagai contoh, dengan rasio **80% data training dan 20% data testing**, maka setiap kelas terdiri dari **120 citra untuk training dan 30 citra untuk testing**. Pembagian ini dilakukan secara acak namun terkontrol untuk menjaga distribusi kelas yang merata. Data training digunakan untuk melatih model, sedangkan data testing digunakan untuk mengevaluasi kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya.

### **4. Pelatihan Model Machine Learning**

Pada tahap ini, data training digunakan untuk membangun model klasifikasi menggunakan tiga algoritma machine learning, yaitu **Support Vector Machine (SVM), K-Nearest Neighbors (KNN), dan Random Forest**. Setiap algoritma dilatih secara terpisah dengan menggunakan data training yang sama agar perbandingan kinerja dapat dilakukan secara adil dan objektif. Proses pelatihan melibatkan pembentukan model berdasarkan fitur yang diekstraksi dari citra fundus serta penyesuaian parameter sesuai dengan karakteristik masing-masing algoritma. Tahap ini bertujuan untuk menghasilkan model yang mampu mengenali pola penyakit fundus secara optimal.


### **5. Evaluasi Model**

Setelah proses pelatihan model selesai, masing-masing model klasifikasi yang dihasilkan menggunakan algoritma Support Vector Machine (SVM), K-Nearest Neighbors (KNN), dan Random Forest selanjutnya diuji menggunakan data testing. Pada tahap ini, model digunakan untuk memprediksi kelas penyakit fundus dari citra yang tidak pernah digunakan selama proses pelatihan, sehingga dapat menggambarkan kemampuan generalisasi model. Hasil prediksi dari setiap algoritma kemudian dicatat dan dibandingkan dengan label kelas sebenarnya untuk mengetahui tingkat ketepatan klasifikasi yang dihasilkan. Evaluasi kinerja model dilakukan secara menyeluruh untuk mengukur tingkat keberhasilan masing-masing algoritma dalam mendeteksi penyakit fundus. Metrik evaluasi yang digunakan meliputi akurasi, precision, recall, F1-score, serta confusion matrix. Akurasi digunakan untuk menilai tingkat ketepatan klasifikasi secara keseluruhan, sedangkan precision dan recall digunakan untuk mengukur ketepatan dan kelengkapan deteksi pada setiap kelas penyakit. Confusion matrix dimanfaatkan untuk menganalisis pola kesalahan klasifikasi yang terjadi pada masing-masing kelas. Hasil evaluasi ini menjadi dasar dalam membandingkan performa ketiga algoritma serta menentukan metode yang memiliki kinerja terbaik dan paling sesuai untuk digunakan sebagai model deteksi penyakit fundus.

### **6. Seleksi Model Berdasarkan Ambang Akurasi**

Berdasarkan hasil evaluasi, dilakukan proses seleksi model untuk menentukan model terbaik. Dalam penelitian ini, ditetapkan ambang batas akurasi sebesar **80%** sebagai kriteria kelayakan model. Model yang memiliki nilai akurasi di atas atau sama dengan 80% dianggap memenuhi syarat dan layak digunakan sebagai model deteksi penyakit fundus. Apabila hasil evaluasi menunjukkan bahwa nilai akurasi belum mencapai ambang batas tersebut, maka dilakukan proses optimasi, seperti penyesuaian parameter model atau perbaikan tahap preprocessing, kemudian proses pelatihan dan pengujian diulang. Tahap





ini bertujuan untuk memastikan bahwa model yang dipilih memiliki kinerja yang optimal dan andal.

### 7. Penentuan Model Deteksi Penyakit Fundus

Tahap akhir penelitian adalah penentuan model deteksi penyakit fundus berdasarkan hasil seleksi model. Model dengan kinerja terbaik, khususnya yang memenuhi kriteria akurasi yang ditetapkan, ditetapkan sebagai model akhir penelitian. Model ini diharapkan dapat digunakan sebagai alat bantu dalam mendeteksi penyakit fundus secara otomatis dan objektif. Pada tahap ini juga dilakukan analisis hasil secara keseluruhan serta penarikan kesimpulan mengenai efektivitas penerapan metode machine learning dalam deteksi penyakit fundus.

## 3. HASIL DAN PEMBAHASAN

Bab hasil dan pembahasan ini menguraikan secara komprehensif hasil implementasi metode machine learning dalam mendeteksi penyakit fundus berdasarkan citra fundus digital. Pada bab ini disajikan hasil pengujian model klasifikasi menggunakan algoritma Support Vector Machine (SVM), K-Nearest Neighbors (KNN), dan Random Forest, yang selanjutnya dianalisis dan dibandingkan kinerjanya berdasarkan metrik evaluasi yang telah ditetapkan. Pembahasan difokuskan pada kemampuan masing-masing model dalam mengklasifikasikan setiap kelas penyakit fundus, tingkat akurasi yang dihasilkan, serta pola kesalahan klasifikasi yang teridentifikasi melalui confusion matrix. Selain itu, bab ini juga membahas kelebihan dan keterbatasan masing-masing algoritma dalam konteks karakteristik dataset yang digunakan, sehingga memberikan gambaran yang jelas mengenai efektivitas penerapan metode machine learning dalam mendukung deteksi penyakit fundus secara otomatis.

### 3.1. Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari 600 citra fundus digital yang terbagi secara seimbang ke dalam empat kelas, yaitu Normal, Background Diabetic Retinopathy, Cataract, dan Glaucoma, dengan masing-masing kelas berjumlah 150 citra untuk detail data terdapat pada Tabel 1. Distribusi data yang seimbang ini bertujuan untuk meminimalkan bias kelas dalam proses klasifikasi dan memastikan bahwa setiap algoritma machine learning diuji secara adil pada seluruh kelas penyakit. Karakteristik dataset ini menjadi faktor penting dalam memengaruhi kinerja model, karena keseimbangan data memungkinkan evaluasi yang lebih objektif terhadap kemampuan masing-masing algoritma dalam mengenali pola penyakit fundus.

**Tabel 1.** Judul Tabel

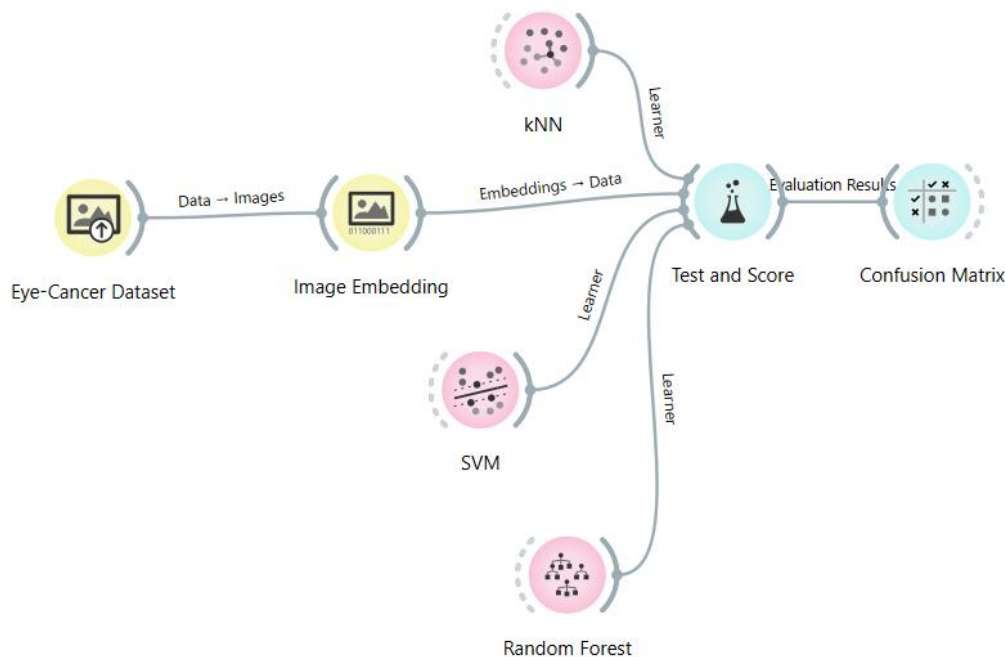
Nama Penyakit	Jumlah Data
Normal	150
Background Diabetic Retinopathy	150
Cataract	150
Glaucoma	150
<b>Total</b>	<b>600</b>

### 3.2. Hasil Evaluasi Umum

Dataset yang digunakan dalam penelitian ini selanjutnya dibagi menjadi data training dan data testing dengan rasio 80:20. Dari total 600 citra fundus, sebanyak 480 citra digunakan sebagai data training dan 120 citra digunakan sebagai data testing. Pembagian data dilakukan secara proporsional pada setiap kelas, sehingga masing-masing kelas terdiri dari 120 citra training dan 30 citra testing. Pembagian ini bertujuan untuk memastikan bahwa model memperoleh data pelatihan yang cukup sekaligus dapat diuji secara objektif terhadap data yang belum pernah dilihat sebelumnya. Pengolahan data



menggunakan orange data mining. Hasil evaluasi kinerja model klasifikasi penyakit fundus ditunjukkan melalui metrik evaluasi yang meliputi akurasi, precision, recall, dan F1-score. Evaluasi dilakukan terhadap tiga algoritma machine learning, yaitu Support Vector Machine (SVM), K-Nearest Neighbors (KNN), dan Random Forest, menggunakan data testing yang telah ditentukan. Alur proses untuk komparasi data seperti terlihat pada Gambar 2.



**Gambar 2.** Alur komparasi metode machine learning

### 3.3. Hasil perbandingan metode


Hasil evaluasi kinerja model klasifikasi penyakit fundus diperoleh berdasarkan pengujian terhadap data testing menggunakan tiga algoritma machine learning, yaitu Random Forest, K-Nearest Neighbors (KNN), dan Support Vector Machine (SVM). Evaluasi dilakukan dengan menggunakan metrik akurasi (CA), precision, recall, dan F1-score sebagai indikator utama performa model. Berdasarkan hasil pengujian, seluruh model menunjukkan kemampuan yang cukup baik dalam mengklasifikasikan penyakit fundus, dengan nilai akurasi rata-rata di atas 80%. Hal ini menunjukkan bahwa pendekatan machine learning yang diterapkan mampu mengenali pola pada citra fundus secara efektif, meskipun terdapat perbedaan performa antar algoritma.

Secara lebih rinci, model Random Forest menghasilkan nilai akurasi sebesar 82,5%, dengan nilai precision, recall, dan F1-score yang relatif seimbang, menunjukkan kestabilan model dalam melakukan klasifikasi. Model KNN menunjukkan peningkatan performa dengan nilai akurasi sebesar 87,7%, yang mengindikasikan bahwa pendekatan berbasis kedekatan jarak antar data mampu bekerja dengan baik pada dataset yang seimbang. Sementara itu, model SVM memberikan hasil terbaik dengan nilai akurasi tertinggi sebesar 88,0%, disertai nilai precision, recall, dan F1-score yang konsisten. Hasil ini menunjukkan bahwa SVM memiliki kemampuan generalisasi yang lebih baik dalam memisahkan kelas-

kelas penyakit fundus, sehingga lebih efektif dalam menangani kompleksitas pola citra fundus dibandingkan metode lainnya.

**Tabel 2.** Hasil Komparasi Metode Machine Learning

Model	Waktu Uji (Test)	Akurasi (CA)	Precision	Recall	F1-Score
Random Forest	0.538	0.825	0.827	0.825	0.825
KNN	0.697	0.877	0.878	0.877	0.877
SVM	1.224	0.880	0.882	0.880	0.878




**Gambar 3.** Hasil Komparasi Metode Machine Learning Untuk Deteksi Penyakit Fundus

## 4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa penerapan metode machine learning mampu memberikan solusi yang efektif dalam mendeteksi penyakit fundus berdasarkan citra fundus digital. Penelitian ini mempelajari perbandingan kinerja tiga algoritma machine learning, yaitu Support Vector Machine (SVM), K-Nearest Neighbors (KNN), dan Random Forest, dalam mengklasifikasikan empat kelas penyakit fundus, yaitu Normal, Background Diabetic Retinopathy, Cataract, dan Glaucoma. Hasil evaluasi menunjukkan bahwa seluruh model mampu mencapai tingkat akurasi di atas 80%, yang menandakan bahwa pendekatan machine learning dapat mengenali pola penyakit fundus secara cukup akurat dan konsisten. Dari ketiga metode yang diuji, SVM menunjukkan performa terbaik dengan nilai akurasi tertinggi, diikuti oleh KNN dan Random Forest.

Penelitian ini memberikan manfaat dalam mendukung proses diagnosis dini penyakit fundus dengan menyediakan pendekatan klasifikasi otomatis yang lebih objektif dan konsisten dibandingkan pemeriksaan manual. Model yang dihasilkan berpotensi digunakan




sebagai sistem pendukung keputusan bagi tenaga medis dalam membantu identifikasi awal penyakit fundus, khususnya pada fasilitas kesehatan dengan keterbatasan jumlah dokter spesialis mata. Namun demikian, penelitian ini masih memiliki beberapa keterbatasan, antara lain penggunaan dataset publik dengan jumlah data yang relatif terbatas serta kondisi citra yang relatif seragam, sehingga belum sepenuhnya merepresentasikan variasi kondisi nyata di lapangan, seperti perbedaan kualitas pencitraan dan tingkat keparahan penyakit.

Untuk penelitian selanjutnya, disarankan untuk memperluas jumlah dan variasi dataset, termasuk penggunaan data dari berbagai sumber dan kondisi pencitraan yang berbeda agar model memiliki kemampuan generalisasi yang lebih baik. Selain itu, penelitian lanjutan dapat mengembangkan metode optimasi parameter, teknik ekstraksi fitur yang lebih kompleks, atau membandingkan metode machine learning klasik dengan pendekatan deep learning. Integrasi aspek interpretabilitas model juga menjadi rekomendasi penting agar hasil klasifikasi dapat lebih mudah dipahami dan dipercaya dalam konteks penerapan klinis.

## 5. REFERENCES

- [1] A. Bustamante-Arias, A. Cheddad, J. Jiménez-Pérez, and A. Rodríguez-García, "Digital Image Processing and Development of Machine Learning Models for the Discrimination of Corneal Pathology: An Experimental Model," *Photonics*, 2021, doi: 10.3390/photonics8040118.
- [2] C. Wangweera and P. Zanini, "Comparison Review of Image Classification Techniques for Early Diagnosis of Diabetic Retinopathy," *Biomed. Phys. & Eng. Express*, 2024, doi: 10.1088/2057-1976/ad7267.
- [3] N. Anton *et al.*, "Assessing Changes in Diabetic Retinopathy Caused by Diabetes Mellitus and Glaucoma Using Support Vector Machines in Combination With Differential Evolution Algorithm," *Appl. Sci.*, 2021, doi: 10.3390/app11093944.
- [4] E. al. Nagaratna Hegde, "Automated Glaucoma Detection in Retinal Fundus Images Using Machine Learning Models," *Jes*, 2024, doi: 10.52783/jes.640.
- [5] S. Gayathri, A. K. Krishna, V. P. Gopi, and P. Palanisamy, "Automated Binary and Multiclass Classification of Diabetic Retinopathy Using Haralick and Multiresolution Features," *Ieee Access*, 2020, doi: 10.1109/access.2020.2979753.
- [6] A. Dhankhar and K. Solanki, "Chi-Square Feature Selection Technique for Student's Performance Prediction," *Indian J. Sci. Technol.*, 2023, doi: 10.17485/ijst/v16i38.921.
- [7] T. Lin and T. Leng, "Code-Free Machine Learning for the Detection of Common Ophthalmic Diseases," *Transl. Vis. Sci. & Technol.*, 2025, doi: 10.1167/tvst.14.9.16.
- [8] F. Aracri, M. G. Bianco, A. Quattrone, and A. Sarica, "Bridging the Gap: Missing Data Imputation Methods and Their Effect on Dementia Classification Performance," *Brain Sci.*, 2025, doi: 10.3390/brainsci15060639.
- [9] Q. Feng, M. Ding, Y. He, Y. Ming, and H. Ren, "Machine Learning-Based Hazard Assessment of Landslides Within the Rainband of Typhoon Lekima," 2024, doi: 10.21203/rs.3.rs-4380308/v1.
- [10] C. Wu, H.-L. Shen, C.-J. Lu, S. Chen, and H. Chen, "Comparison of Different Machine Learning Classifiers for Glaucoma Diagnosis Based on Spectralis OCT," *Diagnostics*, 2021, doi: 10.3390/diagnostics11091718.
- [11] K. Moon and A. K. Jetawat, "Predicting Lung Cancer With K-Nearest Neighbors (KNN): A Computational Approach," *Indian J. Sci. Technol.*, 2024, doi: 10.17485/ijst/v17i21.1192.
- [12] J. S. Lee *et al.*, "Diagnostic Value of Structural and Diffusion Imaging Measures in Schizophrenia," *Neuroimage Clin.*, 2018, doi: 10.1016/j.nicl.2018.02.007.
- [13] M. Song, H. Jung, S. Lee, D. Kim, and M. Ahn, "Diagnostic Classification and Biomarker Identification of Alzheimer's Disease With Random Forest Algorithm," *Brain Sci.*, 2021, doi: 10.3390/brainsci11040453.
- [14] A. D. Bretaña, "Evaluating Deep Learning and Traditional Approaches in the Automated Classification of Retinal Diseases," *J. Inf. Syst. Eng. & Manag.*, 2025, doi:





- 10.52783/jisem.v10i53s.10856.
- [15] H. Lai *et al.*, "Applications of Machine Learning to Diagnosis of Parkinson's Disease," *Brain Sci.*, 2023, doi: 10.3390/brainsci13111546.
- [16] M. S. Alzboon, M. S. Al-Batah, M. Alqaraleh, A. Abuashour, and A. F. Bader, "Early Diagnosis of Diabetes: A Comparison of Machine Learning Methods," *Int. J. Online Biomed. Eng.*, 2023, doi: 10.3991/ijoe.v19i15.42417.
- [17] N. Kour, S. Gupta, and S. Arora, "A Vision-based Clinical Analysis for Classification of Knee Osteoarthritis, Parkinson's Disease and Normal Gait With Severity Based on K-nearest Neighbour," *Expert Syst.*, 2022, doi: 10.1111/exsy.12955.
- [18] V. Singh, V. K. Asari, and R. Rajkumar, "A Deep Neural Network for Early Detection and Prediction of Chronic Kidney Disease," *Diagnostics*, 2022, doi: 10.3390/diagnostics12010116.

