

EKSTRAKSI FITUR CITRA RETINA DENGAN RESNET50 DAN TEKNIK ENSEMBLE UNTUK KLASIFIKASI GANGGUAN PENGLIHATAN DARI CITRA FUNDUS RETINA

Ikhsan Nurazis; Diah Priyawati

**Program Studi Teknik Informatika, Fakultas Komunikasi dan Informatika,
Universitas Muhammadiyah Surakarta**

Abstrak

Gangguan penglihatan seperti glaukoma, katarak, dan retinopati diabetik merupakan masalah kesehatan yang signifikan dan membutuhkan deteksi dini untuk pencegahan yang lebih efektif, sehingga deteksi dini dapat dilakukan dengan memanfaatkan teknologi *machine learning*, yang mampu menganalisis citra retina secara otomatis dan mendalam. Melalui metode *deep learning* berbasis arsitektur ResNet50 yang dikombinasikan dengan teknik *ensemble*, sistem ini dapat mengenali pola dan karakteristik spesifik dari masing-masing gangguan penglihatan, seperti glaukoma, katarak, dan retinopati diabetik. Penelitian ini menggunakan empat jenis citra retina sebagai dataset, yaitu normal, katarak, glaukoma, dan retinopati diabetik. Dalam prosesnya, fitur diekstraksi menggunakan *ResNet50*, kemudian direduksi dimensinya menggunakan *Principal Component Analysis (PCA)*. Selanjutnya, klasifikasi dilakukan dengan mengombinasikan algoritma *Random Forest*, *Support Vector Machine (SVM)*, dan *XGBoost* melalui teknik *Voting Classifier* untuk meningkatkan akurasi model. Hasil penelitian menunjukkan bahwa pendekatan ini berhasil mencapai akurasi 91% dengan nilai *Area Under Curve (AUC)* sebesar 0,99 pada kurva *ROC*, yang menandakan bahwa model ini memiliki potensi kuat untuk mendeteksi gangguan mata secara otomatis, sehingga diharapkan dapat mendukung diagnosis dini dan meningkatkan kualitas perawatan kesehatan mata.

Kata kunci: *Ensemble learning*, Klasifikasi gambar retina, *Principal Component Analysis (PCA)*, *ResNet50*, *Voting Classifier*.

Abstract

Visual impairments such as glaucoma, cataracts, and diabetic retinopathy are significant health issues that require early detection for more effective prevention. Early detection can be achieved by leveraging machine learning technology, which can analyze retinal images automatically and in depth. Using a deep learning method based on the ResNet50 architecture combined with ensemble techniques, this system can recognize specific patterns and characteristics of each eye condition, including glaucoma, cataracts, and diabetic retinopathy. This study utilizes four types of retinal images as the dataset: normal, cataract, glaucoma, and diabetic retinopathy. During the process, features are extracted using ResNet50 and subsequently reduced in dimensionality using Principal Component Analysis (PCA). Classification is then performed by combining Random Forest, Support Vector Machine (SVM), and XGBoost algorithms through a Voting Classifier technique to enhance model accuracy. The results indicate that this approach successfully achieves an accuracy of 91% with an Area Under Curve (AUC) value of 0.99 on the ROC curve, signifying that this model has a solid potential to automatically detect eye disorders, thereby supporting early diagnosis and improving the quality of eye healthcare.

Keywords: Ensemble learning, Retinal image classification, Principal Component Analysis (PCA), ResNet50, Voting Classifier.

1. PENDAHULUAN

Gangguan penglihatan dan kebutaan di seluruh dunia disebabkan oleh berbagai penyakit mata seperti glaukoma, katarak, dan retinopati diabetik. Menurut Organisasi Kesehatan Dunia (WHO), lebih dari 2,2 miliar orang mengalami gangguan penglihatan, dan retinopati diabetik menjadi salah satu penyebab utama kebutaan yang sebenarnya dapat dicegah. Untuk mencegah kerusakan yang lebih lanjut serta meningkatkan kualitas hidup pasien, diagnosis dini menjadi langkah krusial (Ali & Dawood, 2023). Klasifikasi otomatis gambar medis, khususnya gambar retina, memainkan peran penting dalam proses diagnosis dan deteksi dini penyakit-penyakit ini (Hassan et al., 2023). Citra retina menyimpan informasi berharga yang dapat digunakan untuk mengidentifikasi berbagai gangguan mata, sehingga memudahkan tenaga medis dalam pengambilan keputusan yang akurat. Salah satu jenis citra yang penting dalam diagnosis oftalmologi adalah citra fundus retina yang menampilkan secara jelas struktur pembuluh darah, saraf optik, dan makula. Citra ini memberikan visualisasi yang kaya untuk mendeteksi berbagai gangguan mata, termasuk katarak, retinopati diabetik, glaukoma, serta kondisi retina yang normal. Katarak ditandai dengan kekeruhan pada lensa yang mengaburkan detail struktur retina, sementara retinopati diabetik dicirikan oleh pembuluh darah abnormal dan titik-titik perdarahan kecil yang menunjukkan adanya kerusakan vaskular. Pada kasus glaukoma, pembesaran cakram optik akibat tekanan intraokular berlebih berpotensi menyebabkan kerusakan permanen pada saraf optik dan mengganggu penglihatan. Sebaliknya, pada retina normal, pembuluh darah terlihat terdistribusi dengan baik tanpa adanya tanda-tanda perdarahan atau pembengkakan yang mengarah pada gangguan visual. Informasi dari citra fundus ini sangat bermanfaat untuk mendukung diagnosis yang tepat dan memberikan gambaran komprehensif tentang kondisi kesehatan mata pasien (Mulyasari et al., 2024).

Kemajuan dalam teknologi deep learning telah memungkinkan ekstraksi fitur yang lebih kompleks dan akurat dari gambar retina dalam beberapa tahun terakhir. Salah satu model jaringan saraf konvolusi (*CNN*) yang populer adalah *ResNet50*, yang memiliki arsitektur mendalam dan telah terbukti efektif dalam berbagai tugas pengenalan citra (He et al., 2015). *ResNet50* (*Residual Network 50-Layers*) adalah arsitektur *CNN* yang menggunakan blok residual untuk memungkinkan gradien mengalir lebih baik melalui jaringan saraf yang sangat dalam tanpa kehilangan informasi penting. Hal ini mengatasi masalah *vanishing gradient*, yang sering terjadi pada jaringan saraf yang lebih kompleks. Dalam klasifikasi citra retina, *ResNet50* digunakan untuk mengekstraksi fitur visual yang kompleks dari gambar retina, seperti pola pembuluh darah dan saraf optik, yang dapat membantu dalam deteksi berbagai penyakit mata. Model *pretrained ResNet50* yang telah dilatih menggunakan dataset besar seperti *ImageNet*

memungkinkan representasi fitur berkualitas tinggi, tanpa perlu melatih model dari awal, menjadikannya sangat efisien dalam ekstraksi fitur gambar retina (Desiani et al., 2024).

Setelah proses ekstraksi fitur menggunakan ResNet50, teknik ensemble learning diterapkan untuk klasifikasi, dengan menggabungkan beberapa model (Kayathri & Kavitha, 2024), yaitu *Random Forest (RF)*, *Support Vector Machine (SVM)*, dan *XGBoost (XGB)*. *Random Forest* adalah metode berbasis pohon keputusan yang efektif dalam mengatasi *overfitting* dan menghasilkan hasil yang lebih stabil (Yaqoob et al., 2021). *SVM* bekerja dengan mencari *hyperplane* optimal yang memisahkan kelas-kelas dalam ruang fitur, sementara *XGBoost* sebagai model *boosting* mampu meningkatkan akurasi secara bertahap melalui pembenahan kesalahan prediksi dari model sebelumnya. Kombinasi model-model ini diharapkan dapat meningkatkan akurasi klasifikasi dengan mengurangi variabilitas prediksi, serta memberikan solusi yang lebih *robust* dalam mendeteksi penyakit mata secara otomatis.

Penelitian ini bertujuan untuk mengekstraksi fitur dari gambar retina menggunakan model ResNet50, dan selanjutnya menerapkan metode *ensemble* yang menggabungkan *Random Forest*, *SVM*, dan *XGBoost* untuk mengklasifikasikan gambar. Metode yang diusulkan diharapkan dapat memberikan hasil klasifikasi yang lebih akurat dan efektif untuk mengidentifikasi berbagai jenis penyakit mata. Selain itu, metode ini juga dapat berfungsi sebagai alat bantu yang andal dalam diagnosis medis, mendukung upaya deteksi dini serta intervensi yang lebih tepat bagi pasien, sehingga diharapkan dapat meningkatkan kualitas layanan kesehatan mata.

Berdasarkan penelitian sebelumnya yang berfokus pada klasifikasi citra retina menggunakan metode *deep learning* dan *ensemble learning*, beberapa studi telah menunjukkan hasil yang signifikan dalam deteksi gangguan penglihatan, terutama retinopati diabetik dan penyakit mata lainnya. Penelitian oleh Y. Kasnanda Bintang et al. (2024), yang menggunakan *CNN* dengan *Transfer Learning* pada dataset APTOS 2019 BD, mencapai akurasi 96% untuk deteksi retinopati diabetik (Kayathri & Kavitha, 2024). Studi ini menyoroti efektivitas metode *transfer learning* dalam klasifikasi penyakit mata dari citra retina. Selanjutnya, penelitian oleh H. Imaduddin et al. (2024) mengimplementasikan model ResNet-50 untuk klasifikasi gangguan penglihatan dari citra fundus retina dengan akurasi 92%, menunjukkan bahwa arsitektur *ResNet* sangat cocok untuk ekstraksi fitur visual yang kompleks pada citra medis (Imaduddin et al., 2024).

Selain itu, penelitian oleh K. Kayathri dan K. Kavitha (2024) memperkenalkan pendekatan CGSX Ensemble untuk klasifikasi retinopati diabetik, yang menggabungkan machine learning dan deep learning, dengan akurasi akhir 93%. Penelitian lain oleh M. K. Yaqoob et al. (2021)

menggunakan kombinasi *ResNet* untuk ekstraksi fitur dan *Random Forest* untuk klasifikasi retinopati diabetik, menghasilkan akurasi 96% pada dataset Messidor-2 (Yaqoob et al., 2021). Studi ini relevan dengan penelitian saat ini, mengingat teknik yang digunakan serupa, yaitu kombinasi *ResNet50* dan *ensemble learning*.

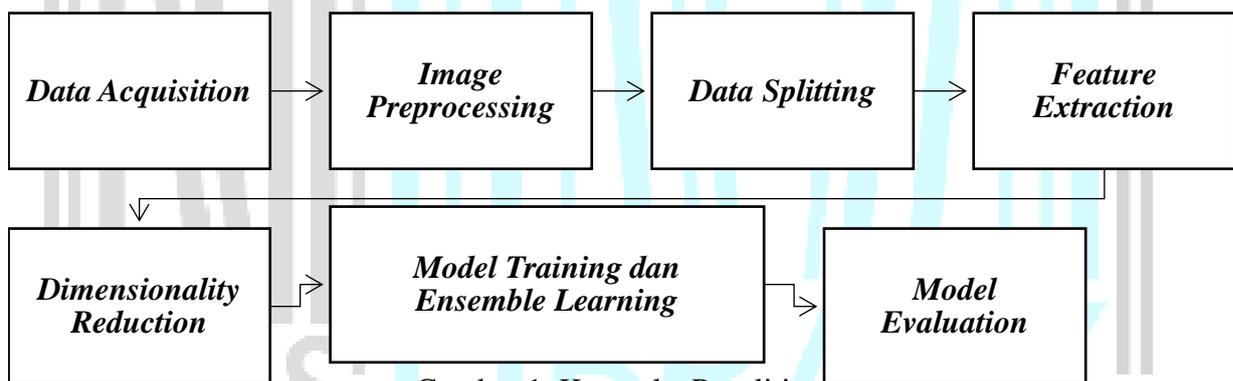
Berikut adalah tabel rangkuman penelitiannya sebelumnya :

Tabel 1. Ringkasan jurnal terkait

NO	PENULIS	TAHUN	JUDUL	METODE	DATASET	AKURASI
1.	K. Kayathri et al. (Kayathri & Kavitha, 2024)	2024	<i>CGSX Ensemble: An Integrative Machine Learning and Deep Learning Approach for Improved Diabetic Retinopathy Classification</i>	<i>CGSX Ensemble Learning</i>	<i>DeepDRiD dataset</i>	93%
2.	M. K. Yaqoob et al. (Yaqoob et al., 2021)	2021	<i>ResNet Based Deep Features and Random Forest Classifier for Diabetic Retinopathy Detection</i>	<i>ResNet Random Forest</i>	<i>Messidor-2, EyePACS</i>	96%
3.	H. Imaduddin et al. (Imaduddin et al., 2024)	2024	<i>Fine-tuning ResNet-50 for the classification of visual impairments from retinal fundus images</i>	<i>Deep Learning dengan ResNet-50</i>	Gambar fundus retina	92%
4.	Y. Kasnanda Bintang et al (Kasnanda Bintang et al., 2024)	2024	Pengembangan Model Deep Learning untuk Deteksi Retinopati Diabetik Menggunakan Metode Transfer Learning	<i>CNN dengan Transfer Learning</i>	<i>APTOS 2019 BD</i>	96%
5.	N. Sikder et al. (Sikder et al., 2021)	2021	<i>Severity classification of diabetic retinopathy using an ensemble learning algorithm</i>	<i>Ensemble Learning Algorithm</i>	<i>APTOS 2019 BD</i>	94.20%

Penelitian sebelumnya menunjukkan bahwa kombinasi *deep learning* dan *ensemble learning* efektif dalam klasifikasi penyakit mata dari citra retina, terutama dalam deteksi retinopati diabetik, salah satu penyebab utama kebutaan yang dapat dicegah. Penggunaan arsitektur seperti *ResNet50* memungkinkan ekstraksi fitur visual yang mendalam dan kompleks, meningkatkan akurasi deteksi penyakit. Teknik *ensemble learning* seperti *Random Forest*, *SVM*, dan *XGBoost* memperkuat performa model dengan menggabungkan prediksi dari berbagai algoritma, yang mengurangi kesalahan prediksi dan meningkatkan generalisasi. Pendekatan ini penting dalam aplikasi medis, di mana akurasi dan stabilitas model sangat dibutuhkan untuk mendukung keputusan klinis. Oleh karena itu, kombinasi kedua metode ini tidak hanya meningkatkan kinerja model, tetapi juga berpotensi diimplementasikan secara luas untuk deteksi gangguan penglihatan dari citra fundus retina.

2. METODE



Gambar 1. Kerangka Penelitian

Penelitian ini mencakup sejumlah langkah-langkah, mulai dari pengumpulan dataset hingga evaluasi kinerja model. Penjelasan mengenai detail dari setiap metode yang digunakan sebagai berikut :

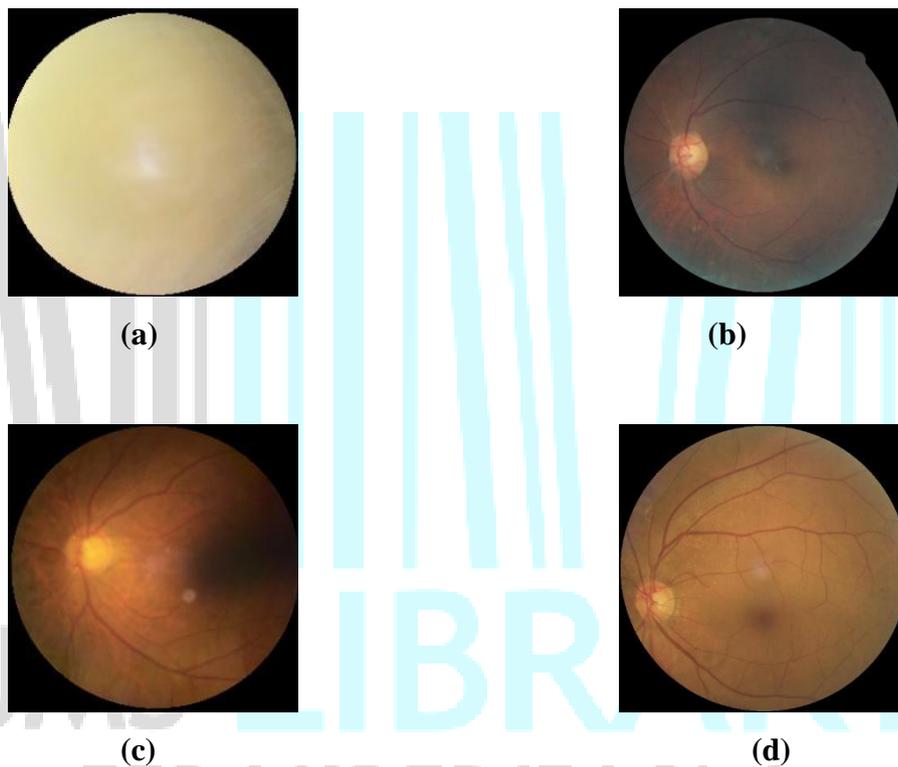
2.1 Data Acquisition (Pengunduhan dan Persiapan Dataset)

Dataset citra retina diunduh dari *Kaggle*, dan file *kaggle.json* digunakan untuk mengautentikasi API. Dataset ini kemudian diekstrak dan diatur sesuai dengan kategori masing-masing yaitu katarak, retinopati diabetik, glaukoma, dan normal. Kumpulan data yang digunakan terdiri dari 4.217 gambar fundus retina, yang mencakup 1.038 gambar yang mewakili katarak, 1.098 gambar yang menunjukkan retinopati diabetik, 1.007 gambar yang menggambarkan kondisi glaukoma, dan 1.074 gambar retina normal. Studi ini melibatkan penggunaan seluruh kumpulan data tersebut. Rincian distribusi kumpulan data dapat dilihat pada Gambar 2, sementara Tabel 1 memberikan penjelasan lengkap tentang alokasinya. Gambar 2(a) menampilkan retina yang terkena katarak, Gambar 2(b) memperlihatkan retina yang terkena

retinopati diabetik, Gambar 2(c) menunjukkan kondisi retina yang terkena galucoma, dan Gambar 2(d) menampilkan retina yang normal (*Eye_diseases_classification*, n.d.).

Tabel 2. Jumlah Gambar pada Setiap Kategori Dataset

No	Kategori	Jumlah Gambar
1	Cataract	1.038
2	Diabetic Retinopathy	1.098
3	Glaucoma	1.007
4	Normal	1.074
Total		4.217



Gambar 2. Gambar Retina (a) katarak, (b) retinopati diabetik, (c) glaucoma, (d) normal.

2.2 Image Preprocessing (Pemuatan dan Preprocessing Gambar)

Setiap gambar diubah ukurannya menjadi 224x224 piksel dan diubah menjadi array. Kemudian, preprocessing dilakukan menggunakan fungsi *preprocess_input* dari *ResNet50* untuk menormalkan nilai piksel sesuai dengan skema *ResNet50*. Ukuran gambar 224x224 piksel dipilih karena merupakan standar yang digunakan dalam pelatihan model *ResNet50* pada dataset *ImageNet*. Dengan memilih ukuran ini, kita memastikan bahwa gambar-gambar yang akan diproses memiliki format yang konsisten dengan model pretrained. Ukuran ini cukup kecil untuk menjaga efisiensi komputasi, namun tetap mampu menangkap detail visual penting dari citra retina, seperti pola pembuluh darah dan saraf optik, yang relevan dalam mendeteksi gangguan penglihatan. Dengan demikian, penggunaan ukuran ini memastikan model dapat

bekerja optimal dalam memproses gambar tanpa mengurangi kualitas informasi yang diperlukan untuk tugas klasifikasi. Fungsi `preprocess_input` dalam *ResNet50* berperan penting dalam menyiapkan gambar untuk model pretrained. Pertama, fungsi ini menskalakan nilai piksel gambar dari rentang [0, 255] menjadi [-1, 1], sesuai dengan skema pelatihan model *ResNet50*. Hal ini memastikan bahwa distribusi nilai piksel input sesuai dengan data pelatihan asli, sehingga meningkatkan akurasi prediksi. Kedua, `preprocess_input` juga melakukan *centering* dan normalisasi dengan mengurangi rata-rata nilai *RGB* berdasarkan dataset *ImageNet*. Ini membantu gambar yang masuk ke model menjadi lebih seimbang dan terpusat, serta mengurangi bias akibat perbedaan intensitas piksel antar gambar. Proses ini penting untuk memastikan model *pretrained* dapat mengidentifikasi fitur-fitur visual yang relevan secara konsisten. Menyiapkan citra dengan ukuran dan format yang sesuai, memastikan data dalam kondisi standar sebelum masuk ke model *deep learning*.

2.3 Data Splitting (Pembagian Data Train dan Test)

Data yang telah diproses dibagi menjadi data latih dan data uji dengan perbandingan 80:20 (Gulshan et al., 2016). Pembagian dataset menjadi 80% data latih dan 20% data uji adalah pendekatan umum dalam machine learning karena mencapai keseimbangan antara pelatihan dan pengujian. Dengan 80% data latih, model memiliki cukup informasi untuk belajar secara efektif tanpa *overfitting*, sementara 20% data uji menyediakan sampel yang cukup untuk mengevaluasi kinerja model secara obyektif. Rasio ini dianggap ideal karena memberikan hasil yang akurat dengan menjaga proporsi kelas yang seimbang, terutama pada dataset yang memiliki distribusi kelas yang tidak merata. Rasio ini juga merupakan praktik yang terbukti efektif dalam berbagai penelitian *machine learning*. Memisahkan dataset untuk pelatihan dan pengujian model, memastikan model dapat diuji secara objektif pada data yang tidak terlihat sebelumnya. Formula *preprocessing* diwakili oleh (1)

$$X_{normalized} = \frac{X - \mu}{\sigma} \quad (1)$$

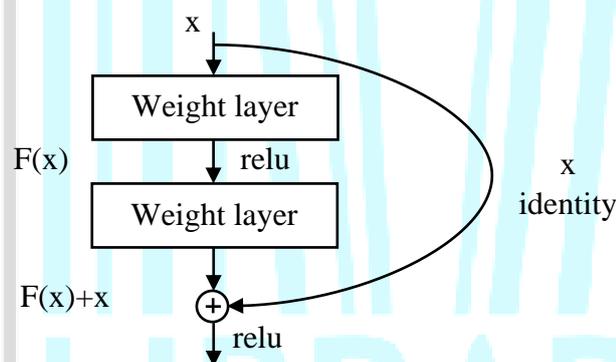
Penjelasan :

- **X**: Nilai piksel citra asli.
- **μ** : Rata-rata nilai piksel dalam dataset.
- **σ** : Standar deviasi nilai piksel.

2.4 Feature Extraction (Ekstraksi Fitur dengan ResNet50)

Model *ResNet50* yang telah dilatih sebelumnya (*pre-trained*) pada dataset *ImageNet* digunakan tanpa bagian top layer (*fully connected layers*) untuk mengekstraksi fitur dari setiap gambar retina. Penghapusan top layer ini memungkinkan model hanya fokus pada ekstraksi fitur yang

relevan dari gambar, sementara proses *pooling* diterapkan untuk mengurangi dimensi *output* dari layer konvolusional. Hasil ekstraksi fitur yang diperoleh kemudian diproses lebih lanjut menggunakan metode *Global Average Pooling (GAP)* untuk menyediakan representasi fitur yang siap digunakan dalam proses klasifikasi. *ResNet (Residual Network)* adalah arsitektur jaringan saraf konvolusi yang memecahkan masalah *vanishing gradient*, yang sering muncul pada model dengan lapisan yang sangat dalam. *ResNet* menggunakan konsep *skip connections*, yang memungkinkan *output* dari satu layer dilewatkan langsung ke layer berikutnya, melewati beberapa lapisan di antaranya. Ini memungkinkan jaringan saraf untuk dilatih pada kedalaman yang sangat besar (seperti *ResNet50* dengan 50 lapisan) tanpa kehilangan akurasi dan stabilitas, sehingga menjadikannya model yang sangat kuat dalam klasifikasi gambar kompleks. Mekanisme mengenai *ResNet50* dapat digambarkan dengan *residual block* seperti gambar berikut :



Gambar 3. Mekanisme *residual block*

Mekanisme *residual block* pada ResNet bertujuan untuk mengatasi masalah degradasi performa pada jaringan yang sangat dalam dengan cara menghubungkan input awal suatu blok langsung ke output melalui *shortcut connection* atau koneksi pintasan (Almoosawi & Khudeyer, 2021). Setiap residual block terdiri dari dua lapisan transformasi (*weight layer*) yang diikuti oleh fungsi aktivasi *ReLU*, yang membentuk fungsi residual $F(x)$. Koneksi pintasan ini memungkinkan input awal x untuk dijumlahkan dengan hasil dari transformasi residual, menghasilkan output akhir berupa $F(x)+x$. Pendekatan ini memungkinkan jaringan untuk belajar secara lebih efisien, karena jaringan hanya perlu mempelajari perubahan kecil (residu) dari input asli, tanpa harus memetakan keseluruhan fungsi target secara langsung. Dalam arsitektur ResNet50, mekanisme ini diterapkan pada banyak lapisan secara bertingkat, sehingga jaringan mampu mencapai kedalaman 50 lapisan tanpa mengalami masalah *vanishing gradient* (Almoosawi & Khudeyer, 2021). Arsitektur ini membuat *ResNet50* sangat efektif

dalam menangkap pola visual yang kompleks, seperti dalam analisis citra retina untuk mendeteksi berbagai kondisi penyakit mata, yang memerlukan detail fitur yang mendalam.

ResNet50 lebih direkomendasikan dibandingkan model transfer learning lainnya, seperti *VGG16* atau *VGG19*, karena kemampuannya mengatasi masalah pada jaringan dalam, seperti *vanishing gradient*, serta efisiensi parameter yang lebih baik (Mahmud et al., 2023). *ResNet50* dirancang untuk menghasilkan representasi fitur yang lebih kaya dan mendetail, yang sangat penting dalam klasifikasi citra medis, termasuk citra retina. Selain itu, *Global Average Pooling (GAP)* digunakan untuk mereduksi dimensi feature map tanpa menggunakan fully connected layers, yang secara signifikan mengurangi jumlah parameter dan risiko *overfitting*, sambil mempertahankan informasi penting dari setiap fitur (Norma Aprilia, n.d.). *GAP* menghasilkan rata-rata dari setiap fitur pada *feature map*, memberikan representasi fitur yang lebih sederhana namun tetap informatif untuk klasifikasi. *Output* dari *layer convolutional* kemudian diproses dengan *Global Average Pooling (GAP)* diwakili oleh formula (2)

$$GAP = \frac{1}{H \times W} = \sum_{i=1}^H \sum_{j=1}^W \text{Feature Map}_{ij} \quad (2)$$

Penjelasan :

- **H** : lebar dari *feature map*,
- **W** : tinggi dari *feature map*,
- $\sum_{i=1}^H \sum_{j=1}^W \text{Feature Map}_{ij}$: nilai dari posisi ke-i,j

2.5 Dimensionality Reduction (Reduksi Dimensi dengan PCA)

Salah satu tantangan utama dalam *machine learning* adalah *overfitting*, yang terjadi ketika model terlalu menyesuaikan diri dengan data latih, sehingga kurang mampu melakukan generalisasi pada data baru. *Overfitting* sering kali disebabkan oleh jumlah fitur yang terlalu banyak, terutama fitur-fitur yang tidak relevan. Model cenderung mempelajari detail yang tidak penting, sehingga menjadi terlalu kompleks. Dalam hal ini, *PCA* membantu mencegah *overfitting* dengan menghilangkan fitur yang tidak signifikan, membuat model lebih sederhana dan lebih mampu melakukan generalisasi (Gewers et al., 2021).

PCA (Principal Component Analysis) adalah salah satu Teknik *dimensionality reduction*. Teknik ini berfungsi untuk mereduksi jumlah fitur tanpa menghilangkan informasi yang signifikan. Pada proses ekstraksi fitur oleh *ResNet50*, lapisan konvolusional terakhir menghasilkan sejumlah besar fitur, yang jika tidak direduksi, dapat menyebabkan proses

komputasi menjadi sangat besar dan memakan waktu. Dengan penerapan *PCA*, fitur-fitur tersebut dirangkum menjadi beberapa komponen utama yang mampu mewakili sebagian besar variabilitas data, sehingga dapat membuat model lebih efisien dan mempercepat proses pelatihan tanpa mengurangi akurasi secara signifikan. Rumus yang digunakan dalam *PCA* ditunjukkan pada formula (3).

$$\mathbf{Z} = \mathbf{XW} \quad (3)$$

Penjelasan :

- \mathbf{X} adalah matriks fitur awal,
- \mathbf{W} adalah matriks *vector eigen* yang dipilih,
- \mathbf{Z} adalah matriks fitur yang telah direduksi

Ini membantu dalam mengurangi kompleksitas komputasi dan menghindari *overfitting*. Mengurangi jumlah fitur yang digunakan sambil mempertahankan informasi yang paling penting, membuat model lebih efisien.

2.6 Model Training dan Ensemble Learning

Tiga algoritma pembelajaran mesin digunakan untuk klasifikasi, yaitu *Random Forest (RF)*, *Support Vector Machine (SVM)*, dan *XGBoost (XGB)* (Alqahtani & Ilyas, 2024) (Li et al., 2023).

Penjelasan mengenai ketiga model adalah sebagai berikut :

- *Random Forest (RF)*: Menggunakan banyak pohon keputusan untuk menghasilkan prediksi dengan voting mayoritas, mengurangi *overfitting*, dan menghasilkan model yang stabil.
- *Support Vector Machine (SVM)*: Mencari *hyperplane* optimal untuk memisahkan kelas-kelas dengan margin maksimum, dan sangat efektif untuk data berdimensi tinggi.
- *XGBoost (XGB)*: Algoritma *boosting* yang sangat efisien dan kuat, yang membangun model secara iteratif untuk memperbaiki kesalahan prediksi dari model sebelumnya, dengan mengutamakan kecepatan dan akurasi.

Ketiga algoritma ini sering digunakan dalam berbagai masalah klasifikasi, termasuk pengolahan citra medis seperti klasifikasi penyakit mata, karena kemampuannya untuk menangani data kompleks dan memberikan hasil yang akurat.

Untuk menemukan konfigurasi terbaik dari setiap model, dilakukan *RandomizedSearchCV* pada masing-masing model dengan menggunakan grid parameter sebagai berikut:

- *Random Forest*: $n_estimators$ (100, 200) dan max_depth (10, 20).
- *SVM*: Parameter C (1, 10) dan $gamma$ (*scale, auto*).

- XGBoost: Parameter *max_depth* (5, 10) dan *n_estimators* (100, 200).

Setelah *hyperparameter tuning* selesai, setiap model dilatih pada data latih yang sudah direduksi dengan PCA.

Untuk meningkatkan akurasi klasifikasi, diterapkan *Voting Classifier* yang menggabungkan ketiga model terbaik dari hasil *tuning* (RF, SVM, dan XGB) menggunakan metode soft voting, di mana prediksi akhir dihitung berdasarkan rata-rata probabilitas dari setiap model. Rumus *soft voting* dalam *ensemble learning* yang ditunjukkan pada formula (4).

$$P_{final} = \frac{1}{n} \sum_{i=1}^n P_{model_i} \quad (4)$$

Penjelasan:

- P_{model_i} : Probabilitas yang diberikan oleh model ke-iii.
- n : Jumlah model dalam ensemble.

2.7 Model Evaluation (Evaluasi Model)

Evaluasi model dilakukan dengan menghitung beberapa metrik performa seperti akurasi, *precision*, *recall*, dan *f1-score* menggunakan *classification report* dari *Scikit-learn*. Penjelasan mengenai masing-masing dari perhitungan matrik sebagai berikut :

2.7.1 Precision

Precision merupakan rasio antara *True Positives (TP)* dengan jumlah total prediksi positif. *Precision* menunjukkan ketepatan model dalam memprediksi suatu kelas. Dalam konteks ini, *precision* tinggi untuk penyakit mata tertentu, seperti retinopati diabetik, menunjukkan bahwa model jarang salah mengidentifikasi kondisi tersebut sebagai penyakit lain. *Precision* penting di sini untuk memastikan prediksi positif benar-benar akurat, sehingga mengurangi kesalahan diagnosis yang dapat merugikan pasien. Rumus untuk *precision* yang ditunjukkan pada formula (5).

$$Precision = \frac{TP}{TP + FP} \quad (5)$$

Penjelasan : Rumus ini menghitung *precision* dengan membagi jumlah *True Positives (TP)* dengan total dari *True Positives (TP)* dan *False Positives (FP)*.

2.7.2 Recall

Recall adalah rasio antara *True Positives (TP)* dengan jumlah total data sebenarnya dalam kelas tersebut. *Recall* menunjukkan kemampuan model dalam mendeteksi seluruh kasus aktual dari kelas tertentu, misalnya, semua kasus glaukoma atau katarak yang sebenarnya ada. *Recall* yang tinggi penting untuk mendeteksi sebanyak mungkin kondisi penyakit mata, sehingga tidak ada kasus yang terlewat, terutama dalam skenario medis. Rumus *recall* yang ditunjukkan pada formula

$$\text{Recall} = \frac{TP}{TP + FN} \quad (6)$$

Penjelasan Rumus: Rumus ini menghitung *recall* dengan membagi jumlah *True Positives (TP)* dengan total dari *True Positives (TP)* dan *False Negatives (FN)*.

2.7.3 F1-Score

F1-Score merupakan rata-rata harmonis antara *precision* dan *recall*. Dalam konteks ini, *F1-score* membantu dalam menyeimbangkan antara kebutuhan ketepatan dan sensitivitas deteksi penyakit, sehingga model mampu memprediksi dengan akurat tanpa mengorbankan sensitivitas. Rumus *F1-Score* yang ditunjukkan pada formula (7).

$$F1 = \frac{2 * (\text{precision} * \text{recall})}{(\text{precision} + \text{recall})} \quad (7)$$

Penjelasan Rumus: Rumus ini mengalikan *precision* dan *recall*, kemudian membaginya dengan jumlah *precision* dan *recall*, dan dikalikan dengan 2.

2.7.4 Support

Support adalah jumlah sampel data sebenarnya (*ground truth*) yang termasuk dalam setiap kelas. Metrik ini menunjukkan seberapa banyak data yang benar-benar termasuk dalam masing-masing kelas, tanpa memperhitungkan apakah model memprediksi dengan benar atau tidak. *Support* memberikan informasi tentang distribusi jumlah data di setiap kelas, yang penting untuk memahami bobot kontribusi setiap kelas dalam model klasifikasi.

2.7.5 Akurasi

Akurasi menunjukkan rasio prediksi yang benar dari total sampel. Metrik ini memberikan gambaran umum tentang seberapa baik model dalam memprediksi seluruh data. Di penelitian ini, akurasi penting untuk menilai keberhasilan model secara keseluruhan dalam mendeteksi empat kategori utama (normal, katarak, glaukoma, dan retinopati diabetik). Rumus akurasi

yang ditunjukkan pada formula (8).

$$\text{Akurasi} = \frac{\text{Jumlah Prediksi Benar}}{\text{Total Data}} \quad (8)$$

Penjelasan Rumus: Rumus ini menghitung akurasi dengan membagi jumlah prediksi yang benar dengan total data.

2.7.6 Macro Average

Macro average menghitung rata-rata precision, recall, dan F1-score di seluruh kelas tanpa mempertimbangkan ukuran kelas. Ini memberikan pandangan tentang performa model secara umum di setiap kelas, berguna untuk memastikan bahwa model bekerja dengan baik di semua kategori, tanpa fokus hanya pada kelas dengan data lebih banyak.

2.7.7 Weighted Average

Weighted average menghitung rata-rata *precision*, *recall*, dan *F1-score* dengan memberikan bobot sesuai dengan jumlah data (*support*) di setiap kelas. Ini memberikan gambaran kinerja yang lebih realistis ketika distribusi kelas tidak seimbang. Dalam penelitian ini, *weighted average* berguna untuk memberikan gambaran yang lebih representatif tentang performa model pada seluruh dataset, terutama saat jumlah data tidak seimbang antar kelas.

Selain itu, *confusion matrix* juga dihasilkan untuk melihat distribusi kesalahan prediksi pada masing-masing kelas. Selanjutnya, performa model juga dievaluasi menggunakan *Receiver Operating Characteristic (ROC) curve* dan nilai *Area Under Curve (AUC)*, yang digunakan untuk mengukur kemampuan model dalam membedakan antara kelas positif dan negatif.

2.7.7.1 ROC (Receiver Operating Characteristic)

ROC adalah kurva yang menggambarkan kinerja model klasifikasi pada berbagai threshold keputusan. *ROC* digunakan untuk mengevaluasi kemampuan model dalam memisahkan kelas positif dan negatif. Kurva ini dibentuk dengan memplot *True Positive Rate (TPR)* atau *Recall* di sumbu y dan *False Positive Rate (FPR)* di sumbu x pada berbagai nilai threshold. *ROC* digunakan untuk menilai trade-off antara *TPR* dan *FPR* dalam model klasifikasi.

2.7.7.2 AUC (Area Under the Curve)

AUC adalah ukuran yang menggambarkan seberapa baik model dapat membedakan antara kelas positif dan negatif. Nilai *AUC* berkisar antara 0 dan 1. Nilai *AUC* yang mendekati 1 menunjukkan model yang sangat baik, sedangkan nilai *AUC* yang mendekati 0.5 menunjukkan model yang hampir tidak dapat memisahkan kelas positif dan negatif. *AUC* merupakan luas di

bawah kurva *ROC*, sehingga semakin besar *AUC*, semakin baik kinerja model. Rumus yang ditunjukkan pada formula (8).

$$TPR = \frac{TP}{TP + FN}, FPR = \frac{FP}{FP + TN} \quad (8)$$

Penjelasan :

- ***TPR*** (*True Positive Rate*) atau sensitivitas adalah metrik yang mengukur seberapa baik model dapat mendeteksi sampel yang sebenarnya positif.
- ***FPR*** (*False Positive Rate*) adalah metrik yang mengukur seberapa sering model salah mengidentifikasi sampel negatif sebagai positif.
- ***TP, FP, TN, FN***: Jumlah prediksi *True Positive, False Positive, True Negative*, dan *False Negative*.

Nilai *FPR* yang rendah menunjukkan bahwa model mampu menahan kesalahan dalam memprediksi kelas negatif sebagai positif. *FPR* biasanya diplot pada sumbu x kurva *ROC*, dan semakin rendah nilai *FPR*, semakin baik kinerja model dalam memisahkan kelas negatif dari positif.

Menilai performa model dalam klasifikasi penyakit mata sangat penting untuk memastikan bahwa model tidak hanya bekerja dengan baik pada data latih, tetapi juga mampu beroperasi secara efektif dan akurat pada data baru yang belum pernah dilihat sebelumnya. Evaluasi ini dilakukan dengan menggunakan beberapa metrik seperti akurasi, *confusion matrix*, dan kurva *ROC*, yang memberikan gambaran menyeluruh tentang kemampuan model dalam mengklasifikasikan gambar retina ke dalam kategori yang benar. Dengan demikian, evaluasi yang teliti dapat memastikan bahwa model tidak mengalami *overfitting*, sehingga dapat diandalkan dalam berbagai kondisi klinis nyata untuk membantu diagnosis penyakit mata secara otomatis.

3. HASIL DAN PEMBAHASAN

Penelitian ini berhasil mengklasifikasikan citra fundus retina menggunakan kombinasi metode ResNet50, PCA, dan Voting Classifier, dengan menghasilkan akurasi keseluruhan sebesar 91.4%. Hasil ini menunjukkan bahwa pendekatan yang diterapkan mampu mendeteksi berbagai kondisi retina, termasuk normal, katarak, glaukoma, dan retinopati diabetik, secara efektif.

Penerapan PCA berhasil mengurangi dimensi fitur dari 2048 menjadi 400 tanpa kehilangan informasi penting, sehingga meningkatkan efisiensi komputasi dan mempercepat proses

pelatihan model. Hal ini memungkinkan penggunaan model dengan kompleksitas tinggi tanpa mengorbankan akurasi. Dengan pemilihan 400 komponen utama, informasi visual yang signifikan tetap terjaga untuk mendukung klasifikasi.

Tabel 3. Laporan Klasifikasi

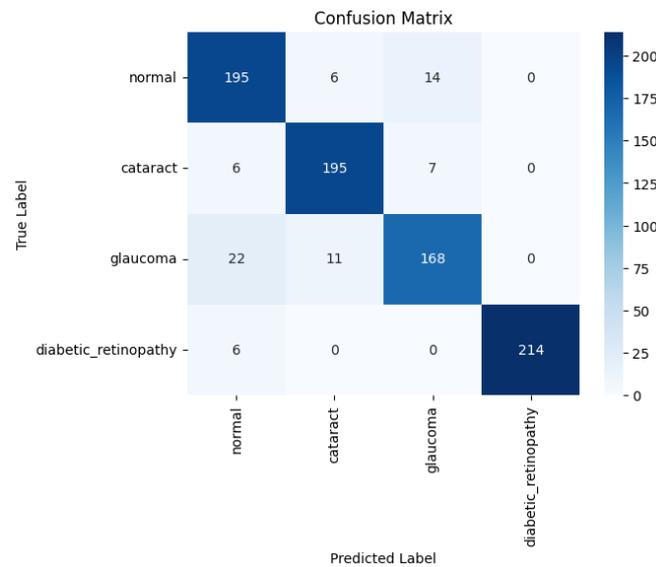
	precision	recall	f1-score	support
Normal	0.85	0.91	0.88	215
<i>Cataract</i>	0.92	0.94	0.93	208
<i>Glaucoma</i>	0.89	0.84	0.86	201
<i>Diabetic Retinopathy</i>	1.00	0.97	0.99	220
<hr/>				
<i>Accuracy</i>			0.91	844
<i>Macro avg</i>	0.92	0.91	0.91	844
<i>Weighted avg</i>	0.92	0.91	0.91	844

Dari Tabel 3. Laporan Klasifikasi, dapat dilihat bahwa model yang diterapkan memiliki performa yang cukup baik dalam mengklasifikasikan empat kategori kondisi mata, yaitu Normal, Cataract, Glaucoma, dan Diabetic Retinopathy. Secara keseluruhan, akurasi model mencapai 0.91 atau 91%, yang menunjukkan bahwa sebagian besar prediksi yang dilakukan oleh model sudah tepat. Selain itu, nilai macro average dan weighted average masing-masing sebesar 0.92 untuk precision, 0.91 untuk recall, dan 0.91 untuk f1-score, mengindikasikan performa yang konsisten di seluruh kelas, baik secara rata-rata sederhana maupun rata-rata tertimbang sesuai jumlah sampel pada tiap kelas.

Secara khusus, kelas Diabetic Retinopathy memiliki precision tertinggi, yaitu 1.00, yang berarti model mampu mengidentifikasi semua sampel yang diprediksi sebagai Diabetic Retinopathy dengan sangat akurat. Recall kelas ini juga cukup tinggi, yaitu 0.97, yang menunjukkan bahwa model dapat mendeteksi hampir seluruh kasus Diabetic Retinopathy yang sebenarnya ada. Hal ini menghasilkan nilai f1-score sebesar 0.99, menunjukkan keseimbangan yang baik antara precision dan recall. Pada kelas Cataract, model mencapai precision sebesar 0.92 dan recall sebesar 0.94, dengan f1-score 0.93, yang menunjukkan bahwa model memiliki performa yang baik dalam mendeteksi kasus-kasus katarak dengan cukup akurat. Sebaliknya, performa terendah terlihat pada kelas Glaucoma, di mana precision mencapai 0.89 dan recall sebesar 0.84, menghasilkan f1-score 0.86. Meskipun demikian, nilai ini masih menunjukkan kemampuan model yang cukup andal untuk mendeteksi glaucoma, meskipun ada beberapa kesalahan dalam klasifikasi. Kelas Normal memiliki precision sebesar 0.85 dan recall 0.91, dengan f1-score 0.88, yang menunjukkan bahwa model masih dapat mendeteksi sebagian besar sampel Normal dengan baik, meskipun terdapat beberapa false positives. Nilai f1-score yang

tinggi di seluruh kelas menunjukkan bahwa model memiliki keseimbangan yang baik antara ketepatan prediksi dan sensitivitas dalam mendeteksi masing-masing kelas.

Secara keseluruhan, hasil ini menunjukkan bahwa model ResNet50 yang diterapkan dalam penelitian ini memiliki kinerja yang baik dan andal dalam mendeteksi kondisi-kondisi mata yang berbeda, dengan tingkat akurasi yang tinggi dan konsistensi performa di seluruh kategori.



Gambar 4. *Confusion Matrix*

Berdasarkan Gambar 4, *Confusion Matrix* memberikan gambaran detail tentang distribusi prediksi benar dan kesalahan klasifikasi model untuk empat kelas: Normal, *Cataract*, *Glaucoma*, dan *Diabetic Retinopathy*. Dari *matrix* ini, kita dapat melihat beberapa informasi penting:

Kelas Normal:

- Prediksi benar untuk kelas Normal adalah 195 (terletak di diagonal dari baris "Normal" dan kolom "Normal").
- Kesalahan klasifikasi yang terjadi meliputi 6 sampel yang salah diklasifikasikan sebagai *Cataract* dan 14 sampel yang salah diklasifikasikan sebagai *Glaucoma*.
- Tidak ada sampel kelas Normal yang diklasifikasikan sebagai *Diabetic Retinopathy*.

Kelas *Cataract*:

- Sebagian besar prediksi benar untuk kelas *Cataract* adalah 195.
- Kesalahan yang terjadi adalah 6 sampel salah diklasifikasikan sebagai Normal, dan 7 sampel salah diklasifikasikan sebagai *Glaucoma*.

- Kesalahan dalam prediksi kelas *Cataract* menunjukkan bahwa model kadang bingung antara kelas *Cataract* dengan Normal dan *Glaucoma*, menunjukkan kemungkinan tumpang tindih fitur visual antara ketiga kelas ini.

Kelas *Glaucoma*:

- Prediksi benar untuk kelas *Glaucoma* adalah 168.
- Kesalahan klasifikasi meliputi 22 sampel yang salah diklasifikasikan sebagai Normal dan 11 sampel yang salah diklasifikasikan sebagai *Cataract*.
- Kesalahan ini menunjukkan bahwa fitur visual untuk kelas *Glaucoma* sering tumpang tindih dengan fitur dari kelas Normal dan *Cataract*, membuatnya sulit untuk dibedakan oleh model.

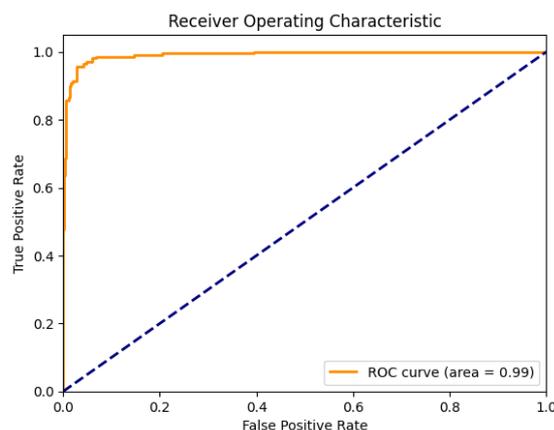
Kelas *Diabetic Retinopathy*:

- Prediksi benar untuk kelas *Diabetic Retinopathy* adalah 214.
- Hanya terdapat sedikit kesalahan, yaitu 6 sampel salah diklasifikasikan sebagai Normal.
- Ini menunjukkan bahwa model sangat efektif dalam mendeteksi *Diabetic Retinopathy*, kemungkinan karena fitur visualnya yang lebih berbeda dibandingkan dengan kelas lainnya.

Kesimpulan dari *Confusion Matrix*:

Model secara keseluruhan berkinerja baik, terutama pada kelas *Diabetic Retinopathy* yang menunjukkan tingkat akurasi tinggi, sedangkan kelas *Glaucoma* mengalami kesalahan klasifikasi yang lebih banyak, menunjukkan bahwa fitur visualnya sering kali mirip dengan kelas Normal dan *Cataract*.

Secara keseluruhan, *Confusion Matrix* ini membantu dalam memahami area di mana model bekerja dengan baik dan di mana kesalahan klasifikasi sering terjadi, terutama pada kelas *Glaucoma*.



Gambar 5. kurva ROC

Gambar 4 menunjukkan kurva *ROC* (*Receiver Operating Characteristic*), yang menggambarkan kinerja model klasifikasi. Sumbu y menunjukkan *True Positive Rate* (*TPR*) atau sensitivitas, sedangkan sumbu x menunjukkan *False Positive Rate* (*FPR*).

- Kurva ROC ini memperlihatkan bagaimana model memisahkan kelas positif dan negatif di berbagai *threshold* prediksi.
- *True Positive Rate* yang tinggi (mendekati 1) dan *False Positive Rate* yang rendah menunjukkan bahwa model dapat mendeteksi kelas positif dengan sangat baik, sembari menjaga kesalahan deteksi kelas negatif tetap rendah.
- Nilai *AUC* (*Area Under the Curve*) sebesar 0.99 menunjukkan performa model yang hampir sempurna. Artinya, model dapat membedakan antara kelas positif dan negatif dengan akurasi yang sangat tinggi.

Secara sederhana, kurva ini menunjukkan bahwa model memiliki kemampuan yang sangat baik dalam mengklasifikasikan data dengan kesalahan prediksi yang sangat kecil.

Penelitian ini berhasil menunjukkan bahwa kombinasi dari model *ResNet 50* untuk ekstraksi fitur, *PCA metode* reduksi dimensi, serta *Voting Classifier* yang menggabungkan *Random Forest (RF)*, *Support Vector Machine (SVM)*, dan *XGBoost*, menghasilkan kinerja yang optimal dengan akurasi sebesar 91,4%. Hal ini membuktikan bahwa pendekatan yang diterapkan mampu mengklasifikasikan citra retina secara efektif, terutama dalam mendeteksi penyakit mata seperti glaukoma, katarak dan retinopati diabetik. Selain itu, nilai *AUC* (*Area Under Curve*) sebesar 0,99 dari kurva ROC menunjukkan kemampuan.

4. PENUTUP

Studi ini menunjukkan bahwa penerapan teknik *transfer learning* dengan model *ResNet50* yang dikombinasikan dengan reduksi dimensi menggunakan *PCA* dan *metode ensemble learning* merupakan pendekatan efektif dalam klasifikasi citra penyakit mata. Dengan tingkat akurasi yang tinggi (91.4%) dan nilai *AUC* yang mendekati sempurna (0.99), metode ini memiliki potensi besar untuk dikembangkan sebagai alat bantu diagnosis medis. Penelitian selanjutnya dapat difokuskan pada pengembangan lebih lanjut dengan mengeksplorasi arsitektur jaringan yang lebih canggih dan menerapkan augmentasi data untuk meningkatkan performa model. Evaluasi pada dataset yang lebih besar dan beragam diperlukan untuk memastikan kemampuan generalisasi model yang lebih baik. Selain itu, integrasi sistem ini ke dalam lingkungan medis nyata melalui aplikasi berbasis web atau mobile dapat menjadi langkah penting. Penggunaan metode segmentasi citra dan optimasi *hyperparameter* seperti

GridSearchCV atau *Bayesian Optimization* juga direkomendasikan untuk lebih meningkatkan akurasi dan efisiensi model. Dengan demikian, teknologi ini diharapkan mampu mendukung deteksi dini yang lebih cepat dan meningkatkan kualitas intervensi medis, sehingga memperbaiki kualitas hidup pasien..

DAFTAR PUSTAKA

- Ali, A. A., & Dawood, F. A. A. (2023). Deep Learning of Diabetic Retinopathy Classification in Fundus Images. *Jurnal Engineering*, 29(12), 139–152. <https://doi.org/10.31026/J.ENG.2023.12.09>
- Almoosawi, N. M., & Khudeyer, R. S. (2021). ResNet-34/DR: A Residual Convolutional Neural Network for the Diagnosis of Diabetic Retinopathy. *Informatika*, 45(7).
- Alqahtani, A. F., & Ilyas, M. (2024). An Ensemble-Based Multi-Classification Machine Learning Classifiers Approach to Detect Multiple Classes of Cyberbullying. *Machine Learning and Knowledge Extraction 2024, Vol. 6, Pages 156-170*, 6(1), 156–170. <https://doi.org/10.3390/MAKE6010009>
- Desiani, A., Primartha, R., Hanum, H., Dewi, S. R. P., Al-Filambany, M. G., Suedarmin, M., & Suprihatin, B. (2024). Weighted Voting Ensemble Learning of CNN Architectures for Diabetic Retinopathy Classification. *Jurnal Infotel*, 16(1). <https://doi.org/10.20895/INFOTEL.V16I1.999>
- eye_diseases_classification*. (n.d.). Retrieved July 7, 2024, from <https://www.kaggle.com/datasets/gunavenkatdoddi/eye-diseases-classification>
- Gewers, F. L., Ferreira, G. R., De Arruda, H. F., Silva, F. N., Comin, C. H., Amancio, D. R., & Costa, L. D. F. (2021). Principal component analysis: A natural approach to data exploration. *ACM Computing Surveys*, 54(4). https://doi.org/10.1145/3447755/SUPPL_FILE/GEWERS.ZIP
- Gulshan, V., Peng, L., Coram, M., Stumpe, M. C., Wu, D., Narayanaswamy, A., Venugopalan, S., Widner, K., Madams, T., Cuadros, J., Kim, R., Raman, R., Nelson, P. C., Mega, J. L., & Webster, D. R. (2016). *Development and Validation of a Deep Learning Algorithm for Detection of Diabetic Retinopathy in Retinal Fundus Photographs Editorial Supplemental content*. <https://doi.org/10.1001/jama.2016.17216>
- Hassan, E., Elmougy, S., Ibraheem, M. R., Hossain, M. S., AlMutib, K., Ghoneim, A., AlQahtani, S. A., & Talaat, F. M. (2023). Enhanced Deep Learning Model for Classification of Retinal Optical Coherence Tomography Images. *Italian National Conference on Sensors*, 23(12). <https://doi.org/10.3390/S23125393>
- He, K., Zhang, X., Ren, S., & Sun, J. (2015). Deep Residual Learning for Image Recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016-December*, 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- Imaduddin, H., Utomo, I. C., & Anggoro, D. A. (2024). Fine-tuning ResNet-50 for the classification of visual impairments from retinal fundus images. *International Journal of Electrical and Computer Engineering*, 14(4), 4175–4182. <https://doi.org/10.11591/ijece.v14i4.pp4175-4182>
- Kasnanda Bintang, Y., Imaduddin, H., Kasnanda, Y., & Corresponding Author, B. (2024). PENGEMBANGAN MODEL DEEP LEARNING UNTUK DETEKSI RETINOPATI DIABETIK MENGGUNAKAN METODE TRANSFER LEARNING. *JIPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, 9(3), 1442–1455. <https://doi.org/10.29100/JIPI.V9I3.5588>
- Kayathri, K., & Kavitha, K. (2024). CGSX Ensemble: An Integrative Machine Learning and Deep Learning Approach for Improved Diabetic Retinopathy Classification. *International*

- Journal of Electrical and Electronics Research*, 12(2), 669–681.
<https://doi.org/10.37391/IJEER.120245>
- Li, W., Yu, S., Yang, R., Tian, Y., Zhu, T., Liu, H., Jiao, D., Zhang, F., Liu, X., Tao, L., Gao, Y., Li, Q., Zhang, J., & Guo, X. (2023). Machine Learning Model of ResNet50-Ensemble Voting for Malignant–Benign Small Pulmonary Nodule Classification on Computed Tomography Images. *Cancers*, 15(22). <https://doi.org/10.3390/cancers15225417>
- Mahmud, M. I., Mamun, M., & Abdelgawad, A. (2023). A Deep Analysis of Transfer Learning Based Breast Cancer Detection Using Histopathology Images. *Proceedings of the 10th International Conference on Signal Processing and Integrated Networks, SPIN 2023*, 198–204. <https://doi.org/10.1109/SPIN57001.2023.10117110>
- Mulyasari, C. R., Hadiana, A. I., & Komarudin, A. (2024). DETEKSI PENYAKIT DIABETES, KATARAK DAN GLAUKOMA PADA CITRA FUNDUS RETINA MATA MANUSIA MENGGUNAKAN CNN DENGAN ARSITEKTUR ALEXNET. *JUMANJI (Jurnal Masyarakat Informatika Unjani)*, 8(1), 53–68. <https://doi.org/10.26874/JUMANJI.V8I1.341>
- Norma Aprilia, P. R. (n.d.). *KLASIFIKASI JENIS KERUSAKAN PADA RETINA DARI CITRA OPTICAL COHERENCE TOMOGRAPHY 2 DIMENSI BERBASIS CONVOLUTIONAL NEURAL NETWORK*.
- Sikder, N., Masud, M., Bairagi, A. K., Arif, A. S. M., Nahid, A. Al, & Alhumyani, H. A. (2021). Severity classification of diabetic retinopathy using an ensemble learning algorithm through analyzing retinal images. *Symmetry*, 13(4). <https://doi.org/10.3390/sym13040670>
- Yaqoob, M. K., Ali, S. F., Bilal, M., Hanif, M. S., & Al-Saggaf, U. M. (2021). ResNet Based Deep Features and Random Forest Classifier for Diabetic Retinopathy Detection. *Italian National Conference on Sensors*, 21(11). <https://doi.org/10.3390/S21113883>