

## PENERAPAN *EXTREME GRADIENT BOOSTING (XGBOOST)* PADA DIAGNOSA PENYAKIT MATA

Ilfauza Febrianty Faisal<sup>1</sup>, Chyquithadanuputri<sup>2</sup>, Ida Mulyadi<sup>3</sup>

University of Muhammadiyah Makassar, Indonesia<sup>1,2,3</sup>

[105841110222@student.unismuh.ac.id](mailto:105841110222@student.unismuh.ac.id)<sup>1</sup>, [chyquithadanuputri@unismuh.ac.id](mailto:chyquithadanuputri@unismuh.ac.id)<sup>2</sup>, [idamulyadi@unismuh.ac.id](mailto:idamulyadi@unismuh.ac.id)<sup>3</sup>

Received: 03-06- 2026

Revised: 15-06-2026

Approved: 25-06-2026

### ABSTRAK

Penelitian ini bertujuan menerapkan algoritma *Extreme Gradient Boosting (XGBoost)* untuk mengklasifikasikan penyakit mata berbasis data gejala pasien, khususnya pada tiga kelas penyakit, yaitu katarak, glaukoma, dan retinopati diabetik. Metode yang digunakan adalah kuantitatif dengan pendekatan *machine learning*. Data penelitian berasal dari RSUD Batara Guru dan terdiri atas 1.041 data pasien setelah melalui tahap *preprocessing*. Sebanyak 15 fitur gejala diekstrak dan digunakan sebagai variabel input, meliputi kabur, mata merah, sensitif cahaya, sakit kepala, gatal, nyeri, mata berair, kelopak mata bengkak, sulit buka mata, warna pudar, sulit melihat malam, floaters, pupil abnormal, mata berat, dan mual. Tahapan penelitian mencakup pemeriksaan data, transformasi nilai gejala, encoding label diagnosa, pemilihan fitur, pembagian data training dan testing, pelatihan model *XGBoost*, serta evaluasi menggunakan *confusion matrix*. Model menghasilkan performa seimbang di atas 93,7% pada seluruh metrik evaluasi, yaitu *accuracy* 93,78%, *precision* 93,80%, *recall* 93,78%, dan *F1-score* 93,75%. Hasil *confusion matrix* menunjukkan bahwa sebagian besar data berhasil diklasifikasikan dengan benar, meskipun masih terdapat kesalahan pada kelas glaukoma karena kemiripan gejala dengan katarak. Dengan demikian, *XGBoost* berpotensi digunakan sebagai sistem pendukung keputusan klinis untuk identifikasi awal penyakit mata berbasis gejala pasien, namun hasil prediksi tetap memerlukan konfirmasi medis oleh tenaga kesehatan.

**Kata Kunci:** *XGBoost, Penyakit Mata, Klasifikasi, Machine Learning, Sistem Pendukung Keputusan Klinis*

### PENDAHULUAN

Kesehatan mata merupakan aspek penting dalam menunjang aktivitas manusia karena sebagian besar kegiatan sehari-hari membutuhkan kemampuan penglihatan yang baik. Gangguan pada organ penglihatan dapat menurunkan kualitas hidup, menghambat produktivitas, serta berpotensi menyebabkan kebutaan apabila tidak terdeteksi dan ditangani sejak dini. Beberapa penyakit mata yang sering ditemukan adalah katarak, glaukoma, dan retinopati diabetik. Ketiga penyakit tersebut memiliki karakteristik klinis yang berbeda, namun pada tahap awal sering menunjukkan gejala yang hampir sama, seperti penglihatan kabur, nyeri mata, sensitif terhadap cahaya, sakit kepala, mata berair, serta gangguan penglihatan pada kondisi tertentu.

Permasalahan utama dalam identifikasi awal penyakit mata adalah adanya kemiripan gejala antarjenis penyakit. Gejala penglihatan kabur, misalnya, dapat ditemukan pada katarak, glaukoma, maupun retinopati diabetik. Kondisi tersebut dapat menyulitkan proses klasifikasi awal apabila hanya mengandalkan pengamatan gejala secara manual. Pada fasilitas kesehatan, pemeriksaan klinis oleh tenaga medis tetap menjadi dasar utama dalam menentukan diagnosis. Namun, pemanfaatan teknologi komputasi dapat digunakan sebagai sistem pendukung untuk membantu proses identifikasi awal secara lebih cepat, objektif, dan konsisten.

Perkembangan teknologi *machine learning* memberikan peluang besar

dalam bidang kesehatan, khususnya untuk membantu proses klasifikasi penyakit berbasis data. Machine learning dapat mempelajari pola dari data historis pasien dan menghasilkan prediksi berdasarkan hubungan antara fitur dan target tertentu. Dalam konteks penelitian ini, fitur yang digunakan berupa gejala pasien, sedangkan target klasifikasi berupa jenis penyakit mata. Salah satu algoritma yang sesuai untuk data tabular klinis adalah Extreme Gradient Boosting (XGBoost). XGBoost merupakan arsitektur gradient boosting berbasis pohon keputusan yang membangun model secara bertahap untuk memperbaiki kesalahan model sebelumnya, serta menggunakan regularisasi untuk mengendalikan kompleksitas model [1]. Dibandingkan algoritma pohon tunggal atau model linier, XGBoost lebih kuat dalam menangani hubungan non-linear, interaksi antarfitur, serta variasi distribusi data, sehingga sering menunjukkan performa kompetitif pada data klinis tabular [2], [3].

State-of-the-art penelitian penyakit mata masih banyak didominasi oleh pendekatan berbasis citra, seperti citra retina, fundus, atau optical coherence tomography. Pendekatan tersebut memiliki keunggulan dalam menangkap informasi visual yang detail, tetapi juga memiliki keterbatasan praktis. Model berbasis citra membutuhkan perangkat pemeriksaan khusus, kualitas citra yang konsisten, kapasitas komputasi yang lebih besar, serta proses anotasi yang memerlukan pakar dan waktu relatif lama. Pada konteks fasilitas kesehatan dengan sumber daya terbatas, pendekatan berbasis data gejala menjadi alternatif yang lebih ringan karena data dapat diperoleh pada tahap anamnesis atau pemeriksaan awal sebelum pasien diarahkan ke pemeriksaan lanjutan.

Beberapa penelitian terdahulu menunjukkan bahwa algoritma machine learning memiliki performa yang baik dalam klasifikasi penyakit. [4] menjelaskan bahwa machine learning dapat digunakan untuk mendeteksi dan mengklasifikasikan penyakit mata melalui pola data yang tersedia. [5] menerapkan machine learning untuk memprediksi retinopati diabetik dan menunjukkan bahwa XGBoost menjadi model terbaik berdasarkan AUC pada data rekam medis pasien diabetes. [6] juga membuktikan bahwa data kesehatan elektronik dapat diolah menggunakan kecerdasan buatan untuk membantu mengidentifikasi pasien yang berisiko mengalami gangguan mata. Penelitian lain pada data klinis tabular menunjukkan bahwa XGBoost mampu bersaing dengan Random Forest, Artificial Neural Network, maupun model konvensional dalam tugas prediksi klinis [2], [3], [7].

Meskipun berbagai penelitian telah membahas penerapan machine learning pada bidang kesehatan mata, sebagian besar masih berfokus pada data citra medis atau satu jenis penyakit tertentu. Oleh karena itu, diperlukan algoritma yang memiliki kemampuan menangani data non-linear serta mampu meningkatkan performa klasifikasi melalui mekanisme ensemble learning seperti XGBoost [1]. Penelitian yang menggunakan data gejala pasien untuk mengklasifikasikan beberapa jenis penyakit mata secara bersamaan masih perlu dikembangkan. Oleh sebab itu, penelitian ini berfokus pada penerapan XGBoost untuk mengklasifikasikan tiga jenis penyakit mata, yaitu katarak, glaukoma, dan retinopati diabetik, berdasarkan data gejala pasien dari RSUD Batara Guru.

Berdasarkan uraian tersebut, rumusan masalah dalam penelitian ini adalah bagaimana penerapan algoritma Extreme Gradient Boosting (XGBoost) dalam mengklasifikasikan jenis penyakit mata berdasarkan gejala pasien, serta bagaimana kinerja model tersebut berdasarkan hasil evaluasi menggunakan confusion matrix, accuracy, precision, recall, dan F1-score. Penelitian ini bertujuan

menerapkan algoritma XGBoost dalam klasifikasi penyakit mata berbasis gejala pasien dan mengevaluasi performa model yang dihasilkan. Kontribusi penelitian ini adalah penerapan XGBoost pada data tabular klinis lokal untuk klasifikasi multikelas penyakit mata, sehingga hasilnya dapat menjadi dasar pengembangan sistem pendukung keputusan klinis pada tahap skrining awal.

## METODE PENELITIAN

Penelitian ini menggunakan metode kuantitatif dengan pendekatan machine learning. Penelitian ini bertujuan untuk menerapkan algoritma Extreme Gradient Boosting (XGBoost) dalam mengklasifikasikan penyakit mata berdasarkan data gejala pasien. Data yang digunakan merupakan data sekunder yang diperoleh dari RSUD Batara Guru, Kabupaten Luwu, Sulawesi Selatan. Objek dalam penelitian ini adalah data pasien dengan gangguan penglihatan yang diklasifikasikan ke dalam tiga jenis penyakit mata, yaitu katarak, glaukoma, dan retinopati diabetik.

Dataset awal yang digunakan dalam penelitian ini berjumlah 1.050 data pasien dengan 17 kolom, yang terdiri atas satu kolom identitas pasien, 15 kolom gejala, dan satu kolom diagnosa. Kolom identitas pasien tidak digunakan dalam proses pemodelan karena hanya berfungsi sebagai penanda data. Setelah dilakukan tahap preprocessing, jumlah data yang digunakan dalam pemodelan menjadi 1.041 data pasien. Data tersebut kemudian digunakan sebagai dasar untuk membangun model klasifikasi penyakit mata menggunakan algoritma XGBoost.

Variabel input dalam penelitian ini adalah 15 gejala penyakit mata, yaitu kabur, mata merah, sensitif cahaya, sakit kepala, gatal, nyeri, mata berair, kelopak mata bengkak, sulit buka mata, warna pudar, sulit melihat malam, floaters, pupil abnormal, mata berat, dan mual. Sementara itu, variabel target adalah diagnosa penyakit mata yang terdiri atas tiga kelas, yaitu katarak, glaukoma, dan retinopati diabetik. Setiap gejala yang semula berbentuk kategorikal dengan nilai “Ya” dan “Tidak” diubah menjadi bentuk numerik, yaitu nilai 1 untuk “Ya” dan nilai 0 untuk “Tidak”. Selanjutnya, label diagnosa juga diubah ke dalam bentuk numerik agar dapat diproses oleh model.

Tahapan penelitian meliputi pengumpulan data, preprocessing data, pemilihan fitur, pembagian data, pelatihan model, pengujian model, dan evaluasi performa. Preprocessing mencakup pemeriksaan struktur data, pengecekan missing value, pengecekan data duplikat, transformasi nilai gejala, dan encoding label diagnosa. Setelah itu, dataset dibagi menjadi data training dan testing dengan rasio 80:20. Dari total 1.041 data, sebanyak 832 data digunakan sebagai data training dan 209 data digunakan sebagai data testing.

Tabel 1. Data Penelitian Sebelum dan Sesudah Preprocessing

Tahapan Data	Jumlah Data	Keterangan
Dataset awal	1.050	Data mentah pasien yang diperoleh dari RSUD Batara Guru sebelum proses preprocessing.
Data tidak digunakan	9	Data dikeluarkan dari proses pemodelan karena teridentifikasi memiliki ketidaksesuaian kualitas data, seperti nilai kosong atau data duplikat.
Dataset akhir	1.041	Data bersih yang digunakan dalam proses pemodelan XGBoost setelah melalui tahap preprocessing.

Tabel 1 menunjukkan bahwa dataset awal berjumlah 1.050 data pasien. Sebelum digunakan dalam proses pemodelan, data terlebih dahulu melalui tahap

preprocessing yang meliputi pemeriksaan struktur data, pengecekan missing value, pengecekan data duplikat, transformasi nilai gejala, dan encoding label diagnosa. Berdasarkan hasil pemeriksaan tersebut, terdapat 9 data yang tidak digunakan karena tidak memenuhi kriteria kualitas data, seperti adanya nilai kosong atau indikasi duplikasi data. Dengan demikian, jumlah data akhir yang digunakan dalam pemodelan XGBoost adalah 1.041 data pasien. Pengurangan data ini dilakukan berdasarkan kualitas baris data, bukan berdasarkan pengurangan kelas penyakit tertentu, sehingga pembahasan utama penelitian tetap berfokus pada data bersih yang digunakan untuk pelatihan dan pengujian model.

Tabel 2. Hyperparameter XGBoost

Hyperparameter	Nilai	Keterangan
objective	multi:softprob	Digunakan karena target memiliki tiga kelas dan model perlu menghasilkan probabilitas setiap kelas.
n_estimators	150	Dipilih melalui tuning awal agar jumlah pohon cukup mempelajari pola tanpa membuat model terlalu kompleks.
max_depth	3	Membatasi kedalaman pohon sehingga model tidak terlalu menyesuaikan data latih.
learning_rate	0,05	Mengatur pembelajaran bertahap agar kontribusi setiap pohon lebih stabil.
subsample	0,8	Menggunakan sebagian data pada setiap iterasi untuk membantu mengurangi risiko overfitting.
colsample_bytree	0,8	Menggunakan sebagian fitur pada setiap pohon agar model tidak bergantung pada fitur tertentu.
eval_metric	mlogloss	Sesuai untuk mengevaluasi kesalahan probabilitas pada klasifikasi multikelas.

Nilai hyperparameter pada Tabel 2 ditentukan berdasarkan tuning awal secara bertahap dengan mempertimbangkan stabilitas performa dan pencegahan overfitting. Pendekatan tersebut digunakan karena ukuran dataset relatif terbatas dan model perlu tetap mampu melakukan generalisasi terhadap data testing.

Teknik analisis data dilakukan menggunakan confusion matrix dan metrik evaluasi klasifikasi. Confusion matrix digunakan untuk melihat jumlah prediksi benar dan salah pada setiap kelas penyakit. Metrik evaluasi meliputi accuracy, precision, recall, dan F1-score. Accuracy digunakan untuk mengetahui tingkat ketepatan model secara keseluruhan, precision untuk mengukur ketepatan prediksi pada setiap kelas, recall untuk mengetahui kemampuan model mengenali data aktual pada tiap kelas, sedangkan F1-score digunakan untuk melihat keseimbangan antara precision dan recall.

## HASIL DAN PEMBAHASAN

### Deskripsi Data Penelitian

Data yang digunakan dalam penelitian ini merupakan data sekunder yang diperoleh dari RSUD Batara Guru. Dataset awal terdiri atas 1.050 data pasien dengan 17 atribut yang meliputi satu atribut identitas pasien, 15 atribut gejala penyakit mata, dan satu atribut diagnosa penyakit. Diagnosa yang digunakan sebagai kelas target terdiri atas tiga kategori, yaitu Katarak, Glaukoma, dan Retinopati Diabetik.

Tanggal Kunjungan	Jenis Kelamin	Usia	Pekerjaan	Kabur	Mata merah	Sensitif cahaya	Sakit kepala	Gatal	Merigi	Mata berair	Kelopak mata bengkak	Sulit buka mata	Warna pudar	Sulit melihat malam	Floaters	Pupil abnormal	Mata berat	Mual	Diagnosa
02/09/2025	P	30 Tahun	Ibu Rumah Tangga	Ya	Tidak	Ya	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Ya	Tidak	Tidak	Tidak	Tidak	Tidak	Katarak
02/09/2025	P	58 Tahun	Ibu Rumah Tangga	Ya	Ya	Ya	Ya	Tidak	Ya	Tidak	Tidak	Tidak	Tidak	Ya	Tidak	Ya	Ya	Ya	Glaukoma
02/09/2025	L	44 Tahun	Virasavasta	Ya	Tidak	Ya	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Ya	Tidak	Tidak	Tidak	Tidak	Tidak	Katarak
03/09/2025	P	38 Tahun	Polisi	Ya	Ya	Ya	Ya	Tidak	Ya	Tidak	Tidak	Tidak	Tidak	Ya	Tidak	Ya	Ya	Ya	Glaukoma
04/09/2025	L	27 Tahun	Virasavasta	Ya	Tidak	Ya	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Ya	Ya	Tidak	Tidak	Tidak	Katarak
04/09/2025	L	40 Tahun	Virasavasta	Ya	Tidak	Ya	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Ya	Ya	Tidak	Tidak	Tidak	Katarak
04/09/2025	P	58 Tahun	PNS	Ya	Ya	Ya	Ya	Tidak	Ya	Tidak	Tidak	Tidak	Tidak	Ya	Tidak	Ya	Ya	Ya	Glaukoma
04/09/2025	L	30 Tahun	Virasavasta	Ya	Tidak	Ya	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Ya	Ya	Tidak	Tidak	Tidak	Katarak
10/09/2025	L	42 Tahun	PLN	Ya	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Ya	Ya	Ya	Tidak	Tidak	Tidak	Retinopati Diabetik
10/09/2025	P	30 Tahun	Virasavasta	Ya	Ya	Ya	Ya	Tidak	Ya	Tidak	Tidak	Tidak	Tidak	Ya	Tidak	Ya	Ya	Ya	Glaukoma
10/09/2025	L	30 Tahun	Virasavasta	Ya	Ya	Ya	Ya	Tidak	Ya	Tidak	Tidak	Tidak	Tidak	Ya	Tidak	Ya	Ya	Ya	Katarak
13/09/2025	P	43 Tahun	Polisi	Ya	Tidak	Ya	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Ya	Ya	Tidak	Tidak	Tidak	Tidak	Katarak
14/09/2025	L	19 Tahun	PNS	Ya	Tidak	Ya	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Ya	Ya	Tidak	Tidak	Tidak	Tidak	Katarak
14/09/2025	L	58 Tahun	PNS	Ya	Tidak	Ya	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Ya	Ya	Tidak	Tidak	Tidak	Tidak	Glaukoma
14/09/2025	L	43 Tahun	PNS	Ya	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Ya	Ya	Ya	Tidak	Tidak	Tidak	Retinopati Diabetik
17/09/2025	L	22 Tahun	Belum/Tidak Bekerja	Ya	Ya	Ya	Ya	Tidak	Ya	Tidak	Tidak	Tidak	Tidak	Ya	Tidak	Ya	Ya	Ya	Glaukoma
18/09/2025	P	41 Tahun	PNS	Ya	Tidak	Ya	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Ya	Ya	Tidak	Tidak	Tidak	Tidak	Katarak
18/09/2025	P	21 Tahun	Pelajar/Mahasiswa	Ya	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Ya	Ya	Ya	Tidak	Tidak	Tidak	Retinopati Diabetik
20/09/2025	P	43 Tahun	PLN	Ya	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Ya	Ya	Ya	Tidak	Tidak	Tidak	Retinopati Diabetik
20/09/2025	P	43 Tahun	PNS	Ya	Ya	Ya	Ya	Tidak	Ya	Tidak	Tidak	Tidak	Tidak	Ya	Tidak	Ya	Ya	Ya	Glaukoma
20/09/2025	L	57 Tahun	PNS	Ya	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Ya	Ya	Ya	Tidak	Tidak	Tidak	Retinopati Diabetik
20/09/2025	P	23 Tahun	Belum/Tidak Bekerja	Ya	Tidak	Ya	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Ya	Ya	Tidak	Tidak	Tidak	Tidak	Katarak
24/09/2025	L	40 Tahun	PNS	Ya	Ya	Ya	Ya	Tidak	Ya	Tidak	Tidak	Tidak	Tidak	Ya	Tidak	Ya	Ya	Ya	Glaukoma
25/09/2025	L	52 Tahun	PNS	Ya	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Ya	Ya	Ya	Tidak	Tidak	Tidak	Retinopati Diabetik
25/09/2025	P	31 Tahun	Virasavasta	Ya	Tidak	Ya	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Ya	Ya	Tidak	Tidak	Tidak	Tidak	Katarak
25/09/2025	L	41 Tahun	PLN	Ya	Ya	Ya	Ya	Tidak	Ya	Tidak	Tidak	Tidak	Ya	Tidak	Ya	Ya	Ya	Ya	Glaukoma
25/09/2025	L	44 Tahun	Virasavasta	Ya	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Ya	Ya	Ya	Tidak	Tidak	Tidak	Retinopati Diabetik
27/09/2025	P	46 Tahun	PLN	Ya	Ya	Ya	Ya	Tidak	Ya	Tidak	Tidak	Tidak	Tidak	Ya	Tidak	Ya	Ya	Ya	Glaukoma
30/09/2025	L	47 Tahun	PLN	Ya	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Ya	Ya	Tidak	Tidak	Tidak	Tidak	Katarak
30/09/2025	P	35 Tahun	Virasavasta	Ya	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Ya	Ya	Ya	Tidak	Tidak	Tidak	Retinopati Diabetik
08/10/2025	L	24 Tahun	Ibu Rumah Tangga	Ya	Ya	Ya	Ya	Tidak	Ya	Tidak	Tidak	Tidak	Tidak	Ya	Tidak	Ya	Ya	Ya	Glaukoma
02/10/2025	L	22 Tahun	Pelajar/Mahasiswa	Ya	Tidak	Ya	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Ya	Ya	Tidak	Tidak	Tidak	Tidak	Katarak
02/10/2025	L	56 Tahun	PNS	Ya	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Ya	Ya	Ya	Tidak	Tidak	Tidak	Retinopati Diabetik
04/10/2025	L	26 Tahun	Virasavasta	Ya	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Ya	Ya	Ya	Tidak	Tidak	Tidak	Retinopati Diabetik
05/10/2025	P	40 Tahun	Polisi	Ya	Ya	Ya	Ya	Tidak	Ya	Tidak	Tidak	Tidak	Tidak	Ya	Tidak	Ya	Ya	Ya	Glaukoma
05/10/2025	P	28 Tahun	Virasavasta	Ya	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Ya	Ya	Ya	Tidak	Tidak	Tidak	Katarak
07/10/2025	P	58 Tahun	PNS	Ya	Tidak	Ya	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Ya	Ya	Tidak	Tidak	Tidak	Tidak	Katarak
08/10/2025	P	37 Tahun	Virasavasta	Ya	Ya	Ya	Ya	Tidak	Ya	Tidak	Tidak	Tidak	Tidak	Ya	Tidak	Ya	Ya	Ya	Glaukoma
08/10/2025	L	23 Tahun	Virasavasta	Ya	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Ya	Ya	Ya	Tidak	Tidak	Tidak	Retinopati Diabetik
08/10/2025	P	44 Tahun	Virasavasta	Ya	Tidak	Ya	Tidak	Tidak	Tidak	Tidak	Tidak	Tidak	Ya	Ya	Tidak	Tidak	Tidak	Tidak	Katarak

Gambar 1. Data Mentah

Dataset awal terdiri atas 1.050 data pasien dengan distribusi awal 418 data katarak, 326 data glaukoma, dan 306 data retinopati diabetik. Setelah proses pembersihan data, jumlah data akhir yang digunakan dalam pemodelan menjadi 1.041 data pasien. Distribusi pada Tabel 3 menunjukkan kondisi dataset awal sebelum data yang tidak memenuhi kriteria kualitas dikeluarkan dari proses pemodelan.

Tabel 3. Distribusi Data Awal Sebelum Preprocessing

Kelas Penyakit	Jumlah Data
Katarak	418
Glaukoma	326
Retinopati Diabetik	306
Total	1.050

### 1. Hasil Preprocessing Data

Tahap preprocessing dilakukan untuk memastikan kualitas data sebelum proses pelatihan model. Tahapan yang dilakukan meliputi pemeriksaan missing value, pengecekan data duplikat, transformasi nilai gejala, dan encoding label diagnosa. Nilai gejala yang semula berbentuk kategorikal “Ya” dan “Tidak” diubah menjadi nilai numerik 1 dan 0. Label diagnosa kemudian diubah ke bentuk numerik menggunakan teknik label encoding.

id	pasien	Kabur	Mata merah	Sensitif cahaya	Sakit kepala	Gatal	Nyeri	Mata berair	Kelopak mata bengkak	Sulit buka mata	Warna pudar	Sulit melihat malam	Floaters	Pupil abnormal	Mata berat	Mual	Diagnosa
1	P001	1	0	1	0	0	0	0	0	0	1	1	0	0	0	0	0 Katarak
2	P002	1	1	1	1	0	1	0	0	0	0	1	0	1	1	1	1 Glaukoma
3	P003	1	0	1	0	0	0	0	0	0	1	1	0	0	0	0	0 Katarak
4	P004	1	1	1	1	0	1	0	0	0	0	1	0	1	1	1	1 Glaukoma
5	P005	1	0	1	0	0	0	0	0	0	1	1	0	0	0	0	0 Katarak
6	P006	1	0	1	0	0	0	0	0	0	1	1	0	0	0	0	0 Katarak
7	P007	1	1	1	1	0	1	0	0	0	0	1	0	1	1	1	1 Glaukoma
8	P008	1	0	1	0	0	0	0	0	0	1	1	0	0	0	0	0 Katarak
9	P009	1	0	0	0	0	0	0	0	0	1	1	1	0	0	0	0 Retinopati Diabetik
10	P010	1	1	1	1	0	1	0	0	0	0	1	0	1	1	1	1 Glaukoma
11	P011	1	1	1	1	0	1	0	0	0	0	1	0	1	1	1	1 Katarak
12	P012	1	0	1	0	0	0	0	0	0	1	1	0	0	0	0	0 Katarak
13	P013	1	0	1	0	0	0	0	0	0	1	1	0	0	0	0	0 Katarak
14	P014	1	0	1	0	0	0	0	0	0	1	1	0	0	0	0	0 Katarak
15	P014	1	0	1	0	0	0	0	0	0	1	1	0	0	0	0	0 Glaukoma

Gambar 2. Dataset Setelah Preprocessing

## 2. Pembagian Data Training dan Testing

Dataset yang telah diproses kemudian dibagi menjadi data training dan data testing menggunakan rasio 80:20. Sebanyak 832 data digunakan sebagai data training dan 209 data digunakan sebagai data testing. Pembagian ini bertujuan untuk menguji kemampuan model dalam melakukan generalisasi terhadap data yang belum pernah digunakan selama proses pelatihan.

Tabel 4. Pembagian Data

Jenis Data	Jumlah
Training	832
Testing	209
Total	1.041

## 3. Hasil Penerapan Model XGBoost

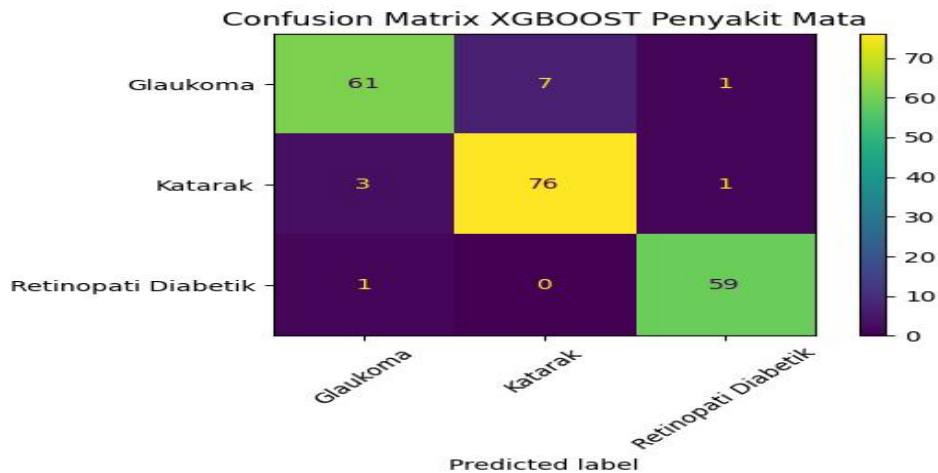
Model XGBoost dibangun menggunakan parameter objective = multi:softprob, n\_estimators = 150, max\_depth = 3, learning\_rate = 0,05, subsample = 0,8, colsample\_bytree = 0,8, dan eval\_metric = mlogloss. Model dilatih menggunakan data training dan kemudian diuji menggunakan data testing. Hasil pengujian menunjukkan bahwa model mampu mengidentifikasi pola gejala pasien dengan baik. Kemampuan tersebut ditunjukkan oleh nilai evaluasi yang relatif tinggi pada seluruh metrik yang digunakan.

Tabel 5. Hasil Evaluasi Model

Metrik	Nilai (%)
Accuracy	93,78
Precision	93,80
Recall	93,78
F1-Score	93,75

Berdasarkan Tabel 5, model XGBoost memperoleh accuracy sebesar 93,78%. Nilai precision, recall, dan F1-score yang berada di atas 93,7% menunjukkan bahwa model memiliki performa yang seimbang dalam membedakan ketiga kelas penyakit mata.

#### 4. Analisis Confusion Matrix



Gambar 3. Confusion Matrix Model XGBoost


Tabel 6. Confusion Matrix

Aktual/Prediksi	Glaukoma	Katarak	Retinopati Diabetik
Glaukoma	61	7	1
Katarak	3	76	1
Retinopati Diabetik	1	0	59

Berdasarkan confusion matrix, model berhasil mengklasifikasikan 196 data dengan benar dari total 209 data testing. Kesalahan klasifikasi paling banyak terjadi antara kelas glaukoma dan katarak. Sebanyak 7 data glaukoma diprediksi sebagai katarak dan 3 data katarak diprediksi sebagai glaukoma. Kondisi ini menunjukkan adanya kemiripan gejala pada kedua penyakit tersebut, terutama penglihatan kabur, sensitivitas cahaya, nyeri mata, dan keluhan tidak nyaman pada mata. Sebaliknya, kelas retinopati diabetik menunjukkan tingkat kesalahan yang rendah karena gejalanya cenderung lebih spesifik, seperti floaters dan gangguan lapang pandang.

#### 5. Analisis Feature Importance XGBoost

Untuk meningkatkan interpretabilitas model, penelitian ini menambahkan analisis feature importance berbasis gain pada XGBoost. Analisis ini digunakan untuk melihat kontribusi relatif setiap gejala dalam proses pembentukan keputusan model. Dalam konteks klinis, feature importance tidak dimaknai sebagai hubungan kausal, tetapi sebagai indikator fitur yang paling banyak membantu model dalam membedakan kelas penyakit.



Gambar 4. Feature Importance Model XGBoost

Gambar 4 menampilkan feature importance dari fitur gejala yang digunakan dalam penelitian, yaitu kabur, mata merah, sensitif cahaya, sakit kepala, gatal, nyeri, mata berair, kelopak mata bengkak, sulit buka mata, warna pudar, sulit melihat malam, floaters, pupil abnormal, mata berat, dan mual. Fitur dengan nilai kontribusi lebih tinggi menunjukkan gejala yang lebih banyak membantu model dalam membedakan kelas katarak, glaukoma, dan retinopati diabetik. Namun, nilai feature importance tidak dimaknai sebagai hubungan sebab-akibat klinis, melainkan sebagai ukuran kontribusi fitur dalam struktur komputasional model XGBoost [7], [8].

Berdasarkan grafik feature importance, beberapa fitur seperti floaters, pupil abnormal, mual, nyeri, warna pudar, dan sensitif cahaya menunjukkan kontribusi penting dalam proses klasifikasi. Floaters membantu model mengenali pola yang berkaitan dengan gangguan retina, sedangkan pupil abnormal, nyeri, sakit kepala, dan mual berkontribusi dalam membedakan pola gejala yang cenderung berkaitan dengan glaukoma. Sementara itu, warna pudar dan sensitif cahaya membantu model mengenali pola gejala yang berkaitan dengan katarak. Adapun gejala kabur tetap relevan secara klinis, tetapi kontribusinya dapat lebih rendah karena gejala tersebut bersifat umum dan dapat muncul pada lebih dari satu jenis penyakit mata.

Dengan demikian, analisis feature importance memberikan nilai tambah terhadap pembahasan hasil penelitian karena membantu menjelaskan fitur gejala yang paling berperan dalam proses prediksi model. Analisis ini memperkuat posisi XGBoost sebagai sistem pendukung keputusan klinis yang tidak hanya menghasilkan performa klasifikasi tinggi, tetapi juga memberikan gambaran interpretatif mengenai pola gejala yang memengaruhi hasil prediksi. Meskipun

demikian, interpretasi feature importance tetap memerlukan kehati-hatian dan tidak dapat menggantikan pemeriksaan klinis oleh tenaga medis.

#### 6. Komparasi dengan Penelitian Terdahulu

Komparasi ini digunakan untuk memperjelas posisi capaian model XGBoost pada klasifikasi penyakit mata berbasis data gejala lokal.

Tabel 7. Komparasi Performa Penelitian

Penelitian	Objek/Data	Algoritma Utama	Metrik Utama	Catatan Komparatif
Keçeli et al. (2024) [5]	Retinopati diabetik berbasis EHR	XGBoost	AUC 0,813	Fokus pada satu penyakit; memakai data rekam medis pasien diabetes.
Yang dan Yang (2025) [9]	Prediksi retinopati diabetik berbasis data klinis dan biokimia	XGBoost	Accuracy 94,67%	Performa tinggi pada prediksi biner retinopati diabetik.
Li et al. (2025) [2]	Prediksi keganasan nodul tiroid berbasis data klinis dan ultrasonografi	XGBoost	Accuracy 85,10%	XGBoost unggul dibanding beberapa model pembanding.
Emir et al. (2026) [3]	Diagnosis trombotopenia terkait sepsis berbasis EHR	XGBoost	Accuracy 91,10% (CV); 87,93% (test)	XGBoost menunjukkan performa dan stabilitas lebih baik dibanding beberapa algoritma pembanding.
Penelitian ini	Klasifikasi multikelas penyakit mata berbasis 15 gejala pasien	XGBoost	Accuracy 93,78%	Menggunakan data gejala lokal dan mengklasifikasikan tiga penyakit mata secara bersamaan.

## PEMBAHASAN

Hasil penelitian menunjukkan bahwa algoritma XGBoost mampu memberikan performa klasifikasi yang tinggi pada data gejala penyakit mata. Temuan ini sejalan dengan penelitian [4] yang menyatakan bahwa machine learning mampu mengidentifikasi pola penyakit mata secara efektif berdasarkan data pasien. Hasil ini juga mendukung penelitian [5] dan [9] yang menunjukkan bahwa model berbasis XGBoost dapat digunakan untuk mendukung prediksi retinopati diabetik. Selain itu, temuan [2] dan [3] memperkuat bahwa XGBoost sesuai digunakan pada data klinis tabular karena mampu menangani interaksi fitur dan menunjukkan performa yang stabil pada tugas klasifikasi medis.

Keunggulan penelitian ini dibandingkan sebagian penelitian sebelumnya terletak pada penggunaan data gejala pasien sebagai fitur utama dalam klasifikasi multikelas. Sebagian penelitian terdahulu berfokus pada analisis citra retina, data ultrasonografi, atau satu jenis penyakit. Penelitian ini mengklasifikasikan tiga jenis penyakit mata secara bersamaan menggunakan 15 fitur gejala yang relatif mudah diperoleh pada tahap pemeriksaan awal. Dengan demikian, pendekatan ini lebih praktis untuk skrining awal, terutama pada fasilitas kesehatan yang belum memiliki perangkat pencitraan mata yang lengkap.

Meskipun demikian, hasil prediksi model tidak dapat menggantikan diagnosis klinis. Model hanya berfungsi sebagai sistem pendukung keputusan

klinis untuk memberikan informasi awal mengenai kemungkinan kelas penyakit. Validasi lanjutan oleh tenaga medis tetap diperlukan karena penyakit mata dapat dipengaruhi oleh faktor lain yang tidak dimasukkan dalam dataset, seperti tekanan intraokular, hasil pemeriksaan retina, riwayat diabetes, kadar gula darah, dan temuan klinis tambahan.

## KESIMPULAN

Berdasarkan hasil penelitian, algoritma Extreme Gradient Boosting (XGBoost) berhasil diterapkan untuk mengklasifikasikan penyakit mata berdasarkan data gejala pasien. Model mampu membedakan tiga jenis penyakit mata, yaitu katarak, glaukoma, dan retinopati diabetik, dengan menggunakan 15 fitur gejala sebagai variabel input. Hasil evaluasi menunjukkan bahwa model memperoleh accuracy sebesar 93,78%, precision sebesar 93,80%, recall sebesar 93,78%, dan F1-score sebesar 93,75%. Hasil tersebut menunjukkan bahwa XGBoost memiliki kinerja yang baik dalam mengenali pola gejala pasien dan mengklasifikasikan penyakit mata secara cukup akurat. Kesalahan klasifikasi paling banyak terjadi antara kelas glaukoma dan katarak karena adanya kemiripan gejala pada kedua penyakit tersebut. Dengan demikian, model XGBoost dapat digunakan sebagai sistem pendukung keputusan klinis untuk identifikasi awal penyakit mata berbasis gejala pasien, namun hasil prediksi model tetap perlu dikonfirmasi melalui pemeriksaan klinis oleh tenaga medis. Keterbatasan penelitian ini terletak pada penggunaan dataset lokal dari satu fasilitas kesehatan dan penggunaan fitur yang masih terbatas pada data gejala pasien, sehingga generalisasi model perlu diuji pada populasi yang lebih luas. Penelitian selanjutnya disarankan menambahkan variasi penyakit mata, memperluas sumber dataset, memasukkan fitur klinis tambahan, serta mengintegrasikan algoritma optimasi hyperparameter seperti grid search, random search, Bayesian optimization, atau metaheuristic optimization agar performa model dapat ditingkatkan secara lebih sistematis.

## DAFTAR PUSTAKA

- [1] T. Chen and C. Guestrin, "XGBoost: A scalable tree boosting system," *Proc. ACM SIGKDD Int. Conf. Knowl. Discov. Data Min.*, vol. 13-17-Aug, no. February, pp. 785–794, 2016, doi: 10.1145/2939672.2939785.
- [2] W. Li, Y. Zhou, Z. Luo, M. Tan, R. Yin, and J. Li, "XGBoost-based machine learning model combining clinical and ultrasound data for personalized prediction of thyroid nodule malignancy," *Front. Endocrinol. (Lausanne)*, vol. 16, no. July, pp. 1–12, 2025, doi: 10.3389/fendo.2025.1639639.
- [3] B. Emir *et al.*, "XGBoost outperforms other machine learning models in diagnosing Sepsis-Associated Thrombocytopenia: a multicenter retrospective study," *Front. Med.*, vol. 13, no. February, pp. 1–14, 2026, doi: 10.3389/fmed.2026.1715551.
- [4] P. Raut, S. Babar, S. Patil, and P. Mahalle, "Machine Learning-Based Detection and Classification of Eye Diseases: A Comprehensive Review and Novel Algorithm," *Int. J. Intell. Syst. Appl. Eng.*, vol. 12, no. 13s, pp. 622–629, 2024.
- [5] T. Keçeli, N. İlhanlı, and K. H. Gülkesen, "Prediction of retinopathy through machine learning in diabetes mellitus," *J. Heal. Sci. Med.*, vol. 7, no. 4, pp. 467–471, 2024, doi: 10.32322/jhsm.1502050.
- [6] J. A. Young, C. W. Chang, C. W. Scales, S. V. Menon, C. E. Holy, and C. A. Blackie, "Machine Learning Methods Using Artificial Intelligence Deployed on Electronic Health Record Data for Identification and Referral of At-Risk

- Patients From Primary Care Physicians to Eye Care Specialists: Retrospective, Case-Controlled Study,” *Jmir Ai*, vol. 3, pp. 1–16, 2024, doi: 10.2196/48295.
- [7] Z. Rafie, M. S. Talab, B. E. Z. Koor, A. Garavand, C. Salehnasab, and M. Ghaderzadeh, “Leveraging XGBoost and explainable AI for accurate prediction of type 2 diabetes,” *BMC Public Health*, vol. 25, no. 1, 2025, doi: 10.1186/s12889-025-24953-w.
- [8] S. Chang, X. Wang, Y. Luo, and L. Jia, “Data augmentation alters feature importance in XGBoost for CVD prediction,” *Sci. Rep.*, vol. 15, no. 1, pp. 1–11, 2025, doi: 10.1038/s41598-025-26228-1.
- [9] P. Yang and B. Yang, “Development and validation of predictive models for diabetic retinopathy using machine learning,” *PLoS One*, vol. 20, no. 2 February, pp. 1–13, 2025, doi: 10.1371/journal.pone.0318226.