

## KLASIFIKASI KATARAK BERDASARKAN *OPTIC DISC* CITRA *FUNDUS* *SMARTPHONE*: PERBANDINGAN EKSTRAKSI CIRI TEKSTUR DAN METODE *NEURAL NETWORK*

Muchtar Ali Setyo Yudono<sup>\*1</sup>, Fabrobi Fazlur Ridha<sup>2</sup>, Dani Mardiyana<sup>3</sup>, Faturrohman Al-Ghozi<sup>4</sup>, Aldi Maulana<sup>5</sup>

<sup>1,2,3,4,5</sup>Universitas Nusa Putra, Sukabumi

Email: <sup>1</sup>muchtar.alisetyo@nusaputra.ac.id, <sup>2</sup>fabrobi.fazlur@nusaputra.ac.id, <sup>3</sup>dani.mardiyana@nusaputra.ac.id, <sup>4</sup>faturrohman.al\_tm22@nusaputra.ac.id, <sup>5</sup>aldi.maulana\_tm21@nusaputra.ac.id

\*Penulis Korespondensi

(Naskah masuk: 19 September 2024, diterima untuk diterbitkan: 11 Februari 2025)

### Abstrak

Kesehatan mata khususnya diagnosis katarak, merupakan aspek penting dalam kesejahteraan individu. Namun, biaya tinggi pemeriksaan sering kali menjadi hambatan, terutama di Indonesia. Kamera *fundus* konvensional, meskipun efektif, memiliki harga yang mahal dan kurang portabel, membatasi aksesibilitas di daerah terpencil. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi katarak otomatis menggunakan kamera *fundus* berbasis *smartphone*, yang menawarkan solusi lebih ekonomis dan portabel dibandingkan perangkat konvensional. Penelitian ini mengevaluasi kinerja tiga algoritma jaringan syaraf tiruan yaitu, *Backpropagation Neural Network* (BPNN), *Probabilistic Neural Network* (PNN), dan *Radial Basis Function Neural Network* (RBFNN), dalam klasifikasi katarak. Metode penelitian meliputi pra-pengolahan citra, segmentasi *optic disc*, ekstraksi ciri tekstur menggunakan *Gray-Level Co-occurrence Matrix* (GLCM) dan Filter Gabor, serta klasifikasi tingkat keparahan katarak ke dalam empat kategori, yaitu retina normal, katarak ringan (*mild*), katarak sedang (*medium*), dan katarak berat (*severe*). Hasil pelatihan menunjukkan rerata nilai akurasi sistem sebesar 96,35%, dengan kinerja terbaik pada ekstraksi ciri GLCM menggunakan PNN (100%) dan Filter Gabor menggunakan PNN (96,88%). Sensitivitas tertinggi dalam pelatihan dicapai oleh metode GLCM dan PNN (100%) untuk kategori katarak normal dan berat. Pada pengujian, sistem mencapai nilai rerata akurasi sebesar 77,98%, dengan hasil terbaik pada ekstraksi ciri GLCM menggunakan PNN (89,29%). Sensitivitas tertinggi pada pengujian diperoleh dengan metode GLCM dan PNN (89,29%) untuk katarak ringan dan berat, sementara spesifisitas tertinggi dicapai oleh GLCM dan BPNN (95,24%) untuk katarak normal. Temuan ini menunjukkan bahwa sistem berbasis *smartphone* ini tidak hanya meningkatkan aksesibilitas diagnosis katarak di daerah terpencil tetapi juga memberikan akurasi yang kompetitif dengan solusi konvensional.

**Kata kunci:** katarak, kamera *fundus smartphone*, *backpropagation neural network* (BPNN), *probabilistic neural network* (PNN), *radial basis function neural network* (RBFNN), *optic disc*

## CATARACT CLASSIFICATION BASED ON *OPTIC DISC* IN *SMARTPHONE FUNDUS* IMAGES: COMPARISON OF TEXTURE FEATURE EXTRACTION AND NEURAL NETWORK METHODS

### Abstract

Eye health, particularly cataract diagnosis, is a crucial aspect of individual well-being. However, the high cost of examinations often poses a barrier, especially in Indonesia. Conventional fundus cameras, while effective, are expensive and less portable, limiting accessibility in remote areas. This research aims to develop an automatic cataract classification system using smartphone-based fundus cameras, offering a more cost-effective and portable solution compared to conventional devices. The study evaluates the performance of three neural network algorithms: *Backpropagation Neural Network* (BPNN), *Probabilistic Neural Network* (PNN), and *Radial Basis Function Neural Network* (RBFNN) for cataract classification. The research methodology includes image preprocessing, *optic disc* segmentation, texture feature extraction using *Gray-Level Co-occurrence Matrix* (GLCM) and Gabor Filter, and classification of cataract severity into four categories: normal retina, mild cataract, medium cataract, and severe cataract. Training results show an average system accuracy of 96.35%, with the best performance on GLCM feature extraction using PNN (100%) and Gabor Filter using PNN (96.88%). The highest sensitivity in training was achieved by GLCM and PNN (100%) for normal and severe cataract

categories. During testing, the system achieved an average accuracy of 77.98%, with the best results for GLCM feature extraction using PNN (89.29%). The highest sensitivity in testing was obtained with GLCM and PNN (89.29%) for mild and severe cataracts, while the highest specificity was achieved by GLCM and BPNN (95.24%) for normal cataracts. These findings indicate that the smartphone-based system not only enhances cataract diagnosis accessibility in remote areas but also provides competitive accuracy compared to conventional solutions.

**Keywords:** cataract, smartphone fundus camera, backpropagation neural network (BPNN), probabilistic neural network (PNN), radial basis function neural network (RBFNN), optic disc

## 1. PENDAHULUAN

Kesehatan mata memainkan peran penting dalam kualitas hidup manusia (Assi et al., 2021). Katarak, sebagai penyebab utama kebutaan, dapat secara signifikan menurunkan ketajaman penglihatan dan berpotensi menyebabkan kebutaan jika tidak ditangani dengan cepat (Rohmah, 2022). Menurut laporan World Health Organization (WHO) pada tahun 2020, katarak menyumbang sekitar 48% dari total kasus kebutaan global. Di Indonesia, survei dari Perhimpunan Dokter Spesialis Mata Indonesia (PERDAMI) dan Balitbangkes menunjukkan bahwa sekitar 81% kasus kebutaan pada populasi usia di atas 50 tahun disebabkan oleh katarak (Agarwal et al., 2019).

Teknologi medis, seperti kamera *fundus*, memainkan peran penting dalam diagnosis dini penyakit mata. Namun, kendala utama yang dihadapi adalah keterbatasan aksesibilitas dan biaya tinggi, terutama di daerah terpencil dan kurang berkembang. Meskipun ada upaya untuk mengembangkan kamera *fundus* berbasis *smartphone*, masih terdapat tantangan dalam deteksi otomatis penyakit mata, termasuk katarak (Wintergerst et al., 2020; Chalam, Chamchikh and Gasparian, 2022). Masalah utama yang mencakup keterbatasan aksesibilitas, tingginya biaya pemeriksaan mata, dan kurangnya teknologi yang terjangkau serta praktis, menghambat diagnosis dan pemantauan penyakit mata. Oleh karena itu, diperlukan pengembangan kamera *fundus* digital berbasis *smartphone* yang lebih ekonomis dan praktis untuk mempercepat deteksi dini, mengurangi biaya perawatan, dan meningkatkan kualitas hidup pasien, khususnya di daerah terpencil (Firdaus et al., 2022; Ahn and Kim, 2024).

Penelitian sebelumnya telah mengembangkan berbagai metode untuk klasifikasi katarak. Sebagai contoh, Penelitian lain Tahun 2019 (Munarto and Yudono, 2019) berhasil mengklasifikasikan katarak ke dalam empat kelas menggunakan metode *Support Vector Machine* dengan akurasi 81%. Meskipun metode ini menunjukkan potensi, terdapat keterbatasan dalam akurasi dan aplikabilitasnya.

Penelitian ini bertujuan untuk menguji kemampuan kamera *fundus* berbasis *smartphone* dalam menghasilkan citra medis yang mendekati kualitas kamera *fundus non-mydratik* standar medis. Fokus utama dari penelitian ini adalah klasifikasi katarak ke dalam empat kategori, yaitu retina normal,

katarak ringan (*mild*), katarak sedang (*medium*), dan katarak berat (*severe*), dengan penekanan pada objek *optic disc* untuk klasifikasi katarak. Sistem ini akan mengevaluasi dua metode ekstraksi ciri tekstur, yaitu *Gray-Level Co-occurrence Matrix* (GLCM) dan Filter Gabor, serta tiga metode jaringan saraf tiruan yaitu *Backpropagation Neural Network* (BPNN), *Probabilistic Neural Network* (PNN), dan *Radial Basis Function Neural Network* (RBFNN).

Pendekatan ini bertujuan untuk meningkatkan akurasi dan efisiensi klasifikasi katarak dengan memanfaatkan *smartphone*, yang diharapkan dapat memperluas akses diagnosis, mempercepat deteksi dini, dan mengurangi biaya pengobatan, terutama di daerah terpencil. Evaluasi sistem akan dilakukan melalui uji klinis untuk mengukur efektivitas diagnosis katarak otomatis. Penelitian ini berfokus pada pengembangan kamera *fundus* berbasis *smartphone* yang terjangkau, serta penerapan teknologi pengolahan citra digital dan jaringan saraf tiruan, dengan tujuan untuk meningkatkan akurasi, efisiensi, dan aksesibilitas diagnosis, sekaligus mengurangi dampak sosial ekonomi dari kebutaan katarak.

## 2. TINJAUAN PUSTAKA

Penelitian mengenai objek *optic disc* dalam klasifikasi katarak menunjukkan potensi besar dalam pemrosesan citra. Misalnya, penelitian "*Automatic Cataract Classification System Using Neural Network Algorithm Backpropagation*" Tahun 2020 (Munarto, Yudono and Permata, 2020) mencapai akurasi 96,4% dengan metode GLCM dan BPNN pada citra retina dari kamera *fundus non-mydratik*.

Studi lain melaporkan akurasi 86,8% dengan PNN (Elveny et al., 2020), dan 89,4% dengan RBFNN (Kamble and Kokate, 2020). Metode ekstraksi ciri berbasis filter Gabor juga menunjukkan hasil signifikan, dengan metode *Random Forest* mencapai akurasi 70,15% (T et al., 2020). Kombinasi Filter Gabor dan BPNN dapat mencapai akurasi 98,80% dalam klasifikasi katarak (Yudono, Isnanto and Triwiyatno, 2021).

Penelitian ini menggunakan data klasifikasi dari citra yang diambil dengan kamera *fundus* berbasis *smartphone* untuk diagnosis katarak di daerah dengan keterbatasan alat medis. Studi ini membandingkan metode ekstraksi fitur GLCM dan Filter Gabor, serta menguji tiga algoritma klasifikasi, yaitu BPNN,

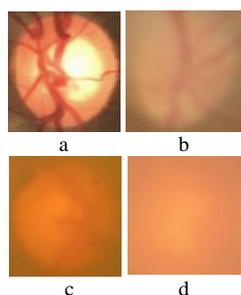
PNN, dan RBFNN, guna menentukan kombinasi optimal. Selain mengevaluasi akurasi, sensitivitas, dan spesifisitas selama pelatihan, penelitian ini juga menilai generalisasi model pada pengujian untuk mengurangi risiko *overfitting*, sehingga relevan untuk penerapan di klinik atau wilayah dengan sumber daya terbatas.

### 3. TERMINOLOGI

Bagian ini membahas teori dan definisi terminologi yang mendukung pengembangan sistem klasifikasi katarak berbasis pengolahan citra digital.

#### 3.1. Katarak

Katarak adalah kekeruhan lensa mata yang menyebabkan penglihatan kabur dan merupakan penyebab utama kebutaan global, terutama pada usia lanjut. Kondisi ini mengurangi kemampuan lensa untuk memfokuskan cahaya ke retina, sehingga menurunkan kualitas citra *fundus* (Skorin and Norberg, 2019). Katarak diklasifikasikan menjadi empat kategori: normal, ringan, sedang, dan berat; pada tingkat berat, *optic disc* dan pembuluh darah tidak terlihat, berpotensi menyebabkan kebutaan total (Juniati and Suwanda, 2022). Penelitian ini berfokus pada analisis *optic disc* sebagai parameter utama dalam klasifikasi katarak. Gambar 1 memperlihatkan klasifikasi *optic disc*: a) Normal (pembuluh darah terlihat); b) Katarak ringan (kekeruhan awal); c) Katarak sedang (kekeruhan jelas); dan d) Katarak berat (struktur *optic disc* tidak terlihat). Pemahaman klasifikasi ini krusial untuk pengembangan sistem deteksi katarak yang lebih efektif (Munarto, Permata and T, 2016; Munarto and Yudono, 2019; Yudono, Isnanto and Triwiyatno, 2021).

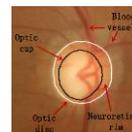


Gambar 1. Klasifikasi *Optic Disc*: a). Normal, b). Katarak *Mild*, c). Katarak *Medium*, d). Katarak *Severe*

#### 3.2. *Optic Disc*

*Optic disc* (OD) adalah area tempat serabut saraf berkumpul sebelum memasuki retina dan berperan penting dalam ekstraksi fitur citra *fundus*. Deteksi OD esensial untuk diagnosis katarak, karena posisinya yang strategis dalam analisis citra retina. Lokasi dan batas OD yang akurat mendukung segmentasi dan ekstraksi fitur tekstur dalam klasifikasi katarak (Rohaya and Husna, 2024). Gambar 2 menunjukkan representasi *optic disc* yang menekankan lokasi dan

batasan relevan untuk analisis citra retina (Gao et al., 2019).



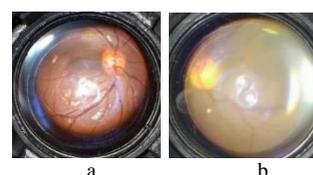
Gambar 2. *Optic Disc* pada Retina

#### 3.3. Dataset Citra Retina

Penelitian ini menggunakan citra *fundus* retina dari kamera *fundus smartphone* untuk klasifikasi katarak. Data citra diambil dari pasien dengan mata normal dan penderita katarak di RS Islam Sultan Agung Semarang, di bawah pengawasan Dokter Spesialis Katarak. Gambar 3 menunjukkan posisi pemeriksa dan pasien saat pengambilan data, yang penting untuk memperoleh citra berkualitas. Gambar 4 menampilkan contoh citra retina: a) normal dengan struktur jelas, dan b) katarak ringan yang menunjukkan kekeruhan awal. Sebanyak 60 citra digunakan, terdiri dari 32 citra untuk pelatihan (8 citra per kelas: normal, katarak ringan, sedang, dan berat) dan 28 citra untuk pengujian (7 citra per kelas), untuk memastikan jumlah yang memadai dalam melatih dan menguji model klasifikasi.



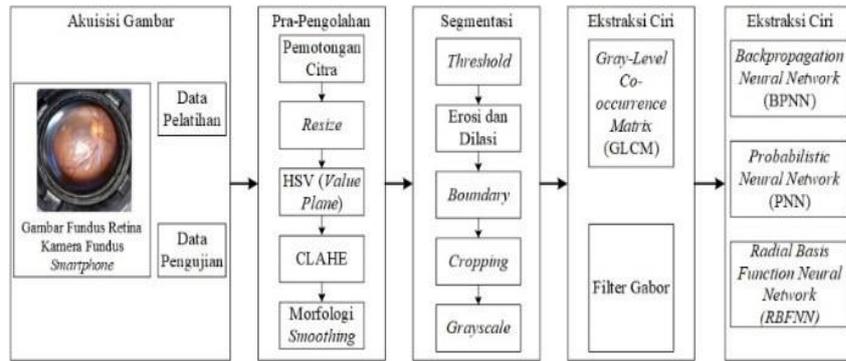
Gambar 3. Posisi Pemeriksa dan Pasien untuk Pengambilan Data Retina dengan Kamera *Fundus Smartphone*.



Gambar 4. Citra Retina yang Diambil Menggunakan Kamera *Fundus Smartphone* pada Pasien di RSI Sultan Agung Semarang: a) Retina Normal, b) Katarak *Mild*

### 4. METODE PENELITIAN

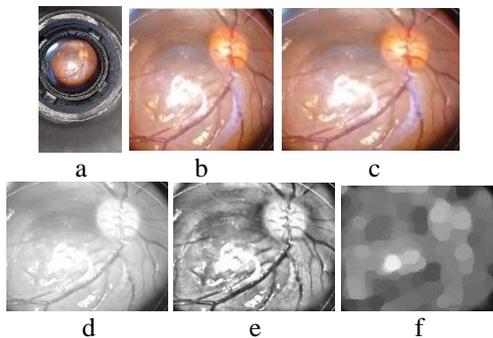
Penelitian ini menggunakan pendekatan sistematis untuk klasifikasi katarak melalui teknologi pengolahan citra digital. Citra retina dikategorikan menjadi empat kelas setelah dilakukan pra-pengolahan dan segmentasi *optic disc*. Ekstraksi fitur diterapkan menggunakan metode *Gray-Level Co-occurrence Matrix* (GLCM) dan Filter Gabor, diikuti dengan klasifikasi menggunakan algoritma *Backpropagation Neural Network* (BPNN), *Probabilistic Neural Network* (PNN), dan *Radial Basis Function Neural Network* (RBFNN). Kinerja sistem dievaluasi berdasarkan akurasi, sensitivitas, dan spesifisitas, yang diilustrasikan dalam Gambar 5 sebagai diagram blok proses klasifikasi katarak.



Gambar 5. Diagram Blok Klasifikasi Katarak

#### 4.1. Pra-Pengolahan

Peningkatan kualitas citra dimulai dengan pra-pengolahan (Asril, Maison and Yudertha, 2019). Langkah pertama adalah pemotongan citra berukuran [593.5, 172.5, 1914, 1758] untuk menghilangkan area yang tidak relevan bagi klasifikasi, diikuti dengan perubahan ukuran citra retina menjadi 1300x1600 piksel guna mengurangi beban komputasi. Selanjutnya, dilakukan konversi warna dari model RGB ke model *Hue, Saturation, Value* (HSV), di mana komponen *value plane* digunakan untuk mendeteksi *optic disc* berdasarkan tingkat kecerahannya.



Gambar 6. Citra Hasil Proses Pra-Pengolahan Klasifikasi Katarak: a. Citra Asli Retina, b. Citra Hasil Pemotongan, c. Citra Hasil *Resize*, d. Citra Hasil *Value Plane*, e. Citra Hasil Operasi CLAHE, f. Citra Hasil Operasi Morfologi *Smoothing*

Tahap berikutnya adalah *Contrast Limited Adaptive Histogram Equalization* (CLAHE) untuk meningkatkan kontras citra, sehingga struktur pembuluh darah dan area di sekitar *optic disc* menjadi lebih jelas terlihat. Pada tahap akhir pra-pengolahan, diterapkan morfologi *smoothing*, yang merupakan kombinasi operasi *opening* dan *closing*, dengan elemen penstruktur berbentuk cakram bernilai 60. Teknik ini bertujuan untuk memperhalus kontur *optic disc* dan mengurangi derau pada citra. Hasil pra-pengolahan terlihat pada Gambar 6.

#### 4.2. Segmentasi

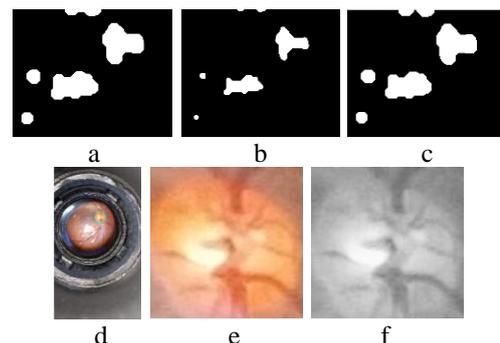
Segmentasi bertujuan untuk merepresentasikan piksel dalam citra ke dalam ruang fitur dan membagi

citra menjadi beberapa *Region of Interest* (ROI) yang homogen berdasarkan kriteria kemiripan tertentu

(Daya et al., 2023). Proses ini penting untuk identifikasi area anatomi, persiapan citra untuk registrasi, serta ekstraksi luas atau volume permukaan. Diagram alir segmentasi ditampilkan pada Gambar 4.

Segmentasi dimulai dengan mengubah citra hasil morfologi *smoothing* menjadi citra biner menggunakan teknik *thresholding* dengan nilai ambang 0,61. Operasi morfologi erosi diterapkan untuk menghilangkan derau dan area yang tidak relevan di luar *optic disc*, diikuti dengan operasi morfologi dilasi untuk memperbesar detail *optic disc* yang terdeteksi. *Boundary extraction* kemudian dilakukan untuk menandai batas *optic disc* dari area lainnya dalam citra retina *fundus*.

Tahap akhir mencakup pemotongan citra *optic disc* untuk memisahkannya dari bagian yang tidak diperlukan, di mana citra *optic disc* yang dihasilkan dikonversi menjadi citra keabuan untuk ekstraksi ciri menggunakan metode GLCM dan Filter Gabor, yang memerlukan citra keabuan sebagai masukan. Hasil proses segmentasi dapat dilihat pada Gambar 7.



Gambar 7. Citra Hasil Proses Segmentasi Klasifikasi Katarak: (a). Citra Biner, (b) Citra Operasi Erosi, (c). Citra Operasi Dilasi, (d). Citra *Boundary Optic Disc*, (e). Citra Pemotongan Citra *Optic Disc*, (f). Citra Konversi kedalam Citra Keabuan dari Hasil Pemotongan Citra *Optic Disc*

#### 4.3. Ekstraksi Ciri

Ekstraksi ciri adalah proses memperoleh fitur utama dari citra sebagai input untuk klasifikasi (Diantarakita. Agus Wahyu Widodo. Muhammad Arif Rahman, 2019). Dalam penelitian ini, dua

metode ekstraksi ciri dibandingkan, yaitu GLCM dan Filter Gabor. Tahap pertama menggunakan Filter Gabor, dengan parameter orientasi sudut ( $\theta$ ) yang menentukan rotasi fitur pada citra yang ditapis. Sudut yang dipilih adalah  $45^\circ$ . Selain itu, panjang gelombang sinusoid ( $\lambda$ ) mempengaruhi resolusi fitur. Nilai  $\lambda$  yang lebih besar menghasilkan fitur yang lebih luas dan kabur, sedangkan nilai  $\lambda$  yang lebih kecil menghasilkan fitur yang lebih tajam. Nilai  $\lambda$  yang digunakan adalah 2. Ekstraksi ciri orde pertama melibatkan analisis histogram citra, yang menunjukkan distribusi tingkat keabuan (0 hingga 255) di sumbu X dan frekuensi pada sumbu Y. Parameter seperti rerata ( $\mu$ ) dihitung dalam ekstraksi orde pertama sesuai dengan persamaan (1).

$$\mu = \sum_n f_n P(f_n) \quad (1)$$

di mana  $f_n$  sebagai tingkat keabuan dan  $P(f_n)$  sebagai probabilitas kemunculannya. Varians ( $\sigma^2$ ) digunakan untuk mengukur variasi dalam histogram citra, sesuai persamaan (2).

$$\sigma^2 = \sum_n (f_n - \mu)^2 p(f_n) \quad (2)$$

menunjukkan frekuensi tiap tingkat keabuan. Entropi (H), sebagai ukuran ketidakteraturan citra, dihitung dengan persamaan (3).

$$H = -\sum_n p(f_n) \cdot \log p(f_n) \quad (3)$$

Tahap kedua ekstraksi ciri menggunakan GLCM untuk menganalisis tekstur objek, dengan mengukur parameter seperti *entropy* orde pertama dan parameter orde kedua, termasuk *Angular Second Moment*, *contrast*, *correlation*, *Inverse Difference Moment*, dan *entropy*. Proses ini dimulai dengan membentuk matriks ko-okurensi, yang merepresentasikan hubungan antar piksel pada berbagai orientasi dan jarak.

Pembentukan matriks ko-okurensi dilakukan dengan menghitung probabilitas ketetanggaan antara dua piksel pada jarak  $d$  dan sudut  $\theta$  ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ , dan  $135^\circ$ ), di mana jarak antar piksel umumnya adalah 1 piksel. Setelah matriks ko-okurensi untuk setiap sudut diperoleh, dilakukan perhitungan matriks ko-okurensi rerata (Mrata-rata) menggunakan persamaan (4), yang dihitung dari rerata matriks ko-okurensi pada semua orientasi sudut yang tersedia.

$$\text{Mrata-rata} = \frac{M(0)+M(45)+M(90)+M(135)}{4} \quad (4)$$

Dengan persamaan (5) hingga (9), beberapa parameter penting dianalisis untuk mengukur tekstur citra. *Angular Second Moment* (ASM), yang dihitung melalui persamaan (5), mengukur homogenitas citra dengan menjumlahkan kuadrat elemen matriks ko-okurensi  $p(i, j)$  untuk setiap pasangan piksel  $(i, j)$ :

$$\text{ASM} = \sum_i \sum_j \{p(i, j)\}^2 \quad (5)$$

*Contrast*, dalam persamaan (6), mengukur penyebaran tekstur citra dengan menjumlahkan produk kuadrat selisih nilai antar elemen matriks  $p(i, j)$ :

$$\text{CON} = \sum_k k^2 [\sum_i \sum_j p(i, j)] \quad (6)$$

*Correlation*, pada persamaan (7), menunjukkan ketergantungan linier tingkat keabuan citra, di mana  $\mu_x$  dan  $\mu_y$  adalah rerata intensitas untuk dua dimensi, dan  $\sigma_x$  dan  $\sigma_y$  adalah simpangan baku intensitas.

$$\text{COR} = \frac{\sum_i \sum_j (ij) \cdot p(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (7)$$

*Inverse Difference Moment* (IDM) pada persamaan (8) mengukur keharmonisan citra dengan menghitung *invers* kuadrat selisih dua tingkat keabuan  $(i - j)$ , yang dikalikan dengan elemen matriks ko-okurensi.

$$\text{IDM} = \sum_i \sum_j \frac{1}{1+(i-j)^2} p(i, j) \quad (8)$$

*Entropy* (ENT) dalam persamaan (9) mengukur ketidakteraturan atau kompleksitas bentuk citra dengan menghitung jumlah produk antara elemen matriks ko-okurensi  $p(i, j)$  dan logaritmanya (Munarto, Yudono and Permata, 2020):

$$\text{ENT}_2 = -\sum_i \sum_j p(i, j) \cdot \log p(i, j) \quad (9)$$

Hasil ekstraksi ciri ini berfungsi sebagai *input* untuk klasifikasi selanjutnya, memungkinkan sistem untuk karakterisasi dan analisis tekstur citra dalam klasifikasi katarak.

#### 4.4. Klasifikasi Jaringan Syaraf Tiruan

Setelah ekstraksi ciri, nilai-nilai dimasukkan ke dalam *Artificial Neural Network* (ANN) untuk pembelajaran dan pengujian. Perbandingan dilakukan antara ekstraksi menggunakan *Gray Level Co-Occurrence Matrix* (GLCM) dan Filter Gabor, serta tiga metode klasifikasi, yaitu *Backpropagation Neural Network* (BPNN), *Probabilistic Neural Network* (PNN), dan *Radial Basis Function Neural Network* (RBFNN). Pada BPNN, bobot diperbaiki melalui perambatan balik kesalahan, dengan fungsi aktivasi seperti *tansig*, *logsig*, dan *purelin*. Algoritma *Levenberg-Marquardt* digunakan dalam klasifikasi katarak. Tabel 1 merinci arsitektur jaringan saraf tiruan, termasuk jumlah neuron di masing-masing lapisan dan parameter seperti toleransi galat (1-e-5) dan laju pembelajaran (0,5), untuk meningkatkan akurasi dan efisiensi klasifikasi. (Yudono et al., 2022).

Algoritma kedua yang diterapkan dalam penelitian ini adalah *Probabilistic Neural Network* (PNN), jaringan saraf tiruan untuk klasifikasi probabilistik yang terdiri dari tiga lapisan: *input*, *hidden* dengan fungsi basis radial Gaussian, dan *output*.

Tabel 1. Rancangan Arsitektur Jaringan Saraf Tiruan Perambatan Balik

No	Karakteristik	Spesifisitas
1	Jumlah Neuron Lapisan Masukan	3 dan 6
2	Jumlah Neuron Lapisan Tersembunyi 1	40
3	Jumlah Neuron Lapisan Tersembunyi 2	50
4	Jumlah Neuron Lapisan Keluaran	4
5	Set Iterasi Maksimum	1500
6	Nilai Unit Momentum	0,1
7	Gradien Minimum	1.00e-08
8	Set Maksimum Unit Momentum	1.00e+14
9	Unit Momentum <i>Decrease</i>	0,2
10	Unit Momentum <i>Increase</i>	11

Fungsi basis radial menghitung jarak antara data masukan dan pusat kelas, dengan parameter *smoothing* ( $\sigma$ ) diatur pada 0.2 untuk ekstraksi ciri GLCM dan 0.1 untuk filter Gabor, guna menyesuaikan pengaruh pusat kelas. PNN mengklasifikasikan data berdasarkan probabilitas tertinggi yang dihitung dari jarak ke pusat kelas, menawarkan kecepatan pelatihan tanpa iterasi berulang dan kemampuan menangani distribusi probabilistik kompleks. Proses klasifikasi melibatkan empat lapisan, yaitu *input*, *pattern*, *summation*, dan *output*, di mana ciri citra katarak diproses di lapisan *pattern* untuk menghasilkan probabilitas kelas berdasarkan *dot product* antara *input* dan bobot pelatihan. Penelitian ini juga membandingkan efektivitas ekstraksi ciri GLCM dan filter Gabor dalam meningkatkan akurasi dan keandalan PNN, dengan parameter  $\sigma$  diatur untuk mencapai keseimbangan optimal antara sensitivitas dan generalisasi. (Specht, 1990; Rani and Prasanth, 2017; Elveny et al., 2020).

*Radial Basis Function Neural Network* (RBFNN) diterapkan untuk mengklasifikasikan citra retina menjadi empat klasifikasi, yaitu retina normal, katarak ringan, katarak sedang, dan katarak berat. RBFNN terdiri dari tiga lapisan, yaitu *input*, tersembunyi, dan *output*, dengan fitur dari GLCM dan Filter Gabor sebagai *input*. Di lapisan tersembunyi, fungsi basis radial Gaussian menghitung jarak input terhadap pusat data pelatihan, memungkinkan pemisahan pola non-linear. Parameter *spread* ditetapkan pada 1 dan toleransi galat pada 1e-3, dengan pelatihan dilanjutkan hingga kesalahan di bawah 0,001. Jumlah neuron awal adalah 28 ( $K = 28$ ) dengan maksimum iterasi 50 ( $K_i = 50$ ). Klasifikasi prediksi dihasilkan dari bobot neuron di lapisan *output*, yang dievaluasi menggunakan akurasi, sensitivitas, dan spesifisitas untuk menilai efektivitas model.

Tabel 2 menunjukkan skenario penelitian untuk mengevaluasi efektivitas kombinasi metode ekstraksi fitur dan teknik klasifikasi dalam analisis citra retina. Skenario 1 hingga 3 menerapkan GLCM untuk ekstraksi ciri, dengan klasifikasi menggunakan BPNN, PNN, atau RBFNN. Skenario 4 hingga 6 menggunakan Filter Gabor untuk ekstraksi fitur dengan teknik klasifikasi yang sama. Tujuan pengaturan ini adalah untuk menilai kinerja setiap metode dalam mengidentifikasi klasifikasi katarak

dan kondisi retina lainnya, sebagaimana ditunjukkan pada Tabel 2.

Tabel 2. Skenario Penelitian

Skenario	Ekstraksi Ciri	Metode
1	GLCM	BPNN
2	GLCM	PNN
3	GLCM	RBFNN
4	Filter Gabor	BPNN
5	Filter Gabor	PNN
6	Filter Gabor	RBFNN

Evaluasi kinerja model klasifikasi mencakup pengukuran sensitivitas, spesifisitas, dan akurasi. Metrik ini menggambarkan kemampuan model dalam mengidentifikasi kelas target, menghindari kesalahan pada kelas non-target, serta menilai tingkat akurasi keseluruhan dalam membedakan antar kelas (Swastika, 2020; Yudono, Isnanto and Triwiyatno, 2021). Tabel 3 menunjukkan contoh *confusion matrix* yang diterapkan dalam klasifikasi dengan empat kelas.

Tabel 3. *Confusion Matrix* pada Klasifikasi 4 Kelas

Kelas Prediksi	Kelas Dikenali			
	A	B	C	D
A	$tp_A$	$e_{AB}$	$e_{AC}$	$e_{AD}$
B	$e_{BA}$	$tp_B$	$e_{BC}$	$e_{BD}$
C	$e_{CA}$	$e_{CB}$	$tp_C$	$e_{CD}$
D	$e_{DA}$	$e_{DB}$	$e_{DC}$	$tp_D$

Notasi dan persamaan yang digunakan dalam perhitungan ini dimulai dengan sensitivitas untuk kelas A, yang dihitung sebagai persentase *True Positive* (TP) terhadap jumlah data yang sebenarnya berasal dari kelas A dan jumlah kesalahan klasifikasi pada kelas lainnya. Persamaan untuk menghitung sensitivitas kelas A dinyatakan dalam Persamaan (10) sebagai berikut.

$$\frac{TP}{TP+FN} = \frac{tp_A}{tp_A + e_{AB} + e_{AC} + e_{AD}} \times 100\% \quad (10)$$

Sensitivitas ini berfungsi untuk menilai kemampuan model dalam mengidentifikasi sampel dari kelas A dengan akurat. Spesifisitas untuk kelas A dihitung sebagai rasio antara *True Negative* (TN) dan *False Positive* (FP) yang terkait dengan kelas tersebut. Persamaan untuk menghitung spesifisitas kelas A dinyatakan dalam Persamaan (11) sebagai berikut.

$$\frac{\text{Total TN}}{\text{Total TN} + \text{Total FP}} = \frac{tp_B + e_{BC} + e_{BD} + e_{CB} + tp_C + e_{CD} + e_{DB} + e_{DC} + tp_D}{tp_B + e_{BC} + e_{BD} + e_{CB} + tp_C + e_{CD} + e_{DB} + e_{DC} + tp_D + e_{BA} + e_{CA} + e_{DA}} \quad (11)$$

Spesifisitas mencerminkan kemampuan model untuk tidak mengidentifikasi kelas A saat sampel berasal dari kelas lain. Perhitungan sensitivitas dan spesifisitas untuk kelas B, C, dan D mengikuti pola yang sama. Sebagai contoh, sensitivitas untuk kelas B dihitung dengan menggunakan Persamaan (12) sebagai berikut.

$$\frac{TP}{TP+FN} = \frac{tp_B}{tp_B + e_{BA} + e_{BC} + e_{BD}} \times 100\% \quad (12)$$

Spesifisitas untuk kelas B dihitung menggunakan Persamaan (13) sebagai berikut.

$$\frac{TN}{TN+FP} = \frac{tpA+e_{AC}+e_{AD}+e_{CA}+tpC+e_{CD}+e_{DA}+e_{DC}+tpD}{tpA+e_{AC}+e_{AD}+e_{CA}+tpC+e_{CD}+e_{DA}+e_{DC}+tpD+e_{AB}+e_{CB}+e_{DB}} \times 100\% \quad (13)$$

Sensitivitas dan spesifisitas untuk kelas C dan D dihitung dengan menggunakan Persamaan (14) dan (15) sebagai berikut.

$$\frac{TP}{TP+FN} = \frac{tpC}{tpC+e_{CA}+e_{CB}+e_{CD}} \times 100\% \quad (14)$$

$$\frac{TN}{TN+FP} = \frac{tpA+e_{AB}+e_{AC}+e_{BA}+tpB+e_{BC}+e_{CA}+e_{CB}+tpC}{tpA+e_{AB}+e_{AC}+e_{BA}+tpB+e_{BC}+e_{CA}+e_{CB}+tpC+e_{AD}+e_{BD}+e_{DC}} \times 100\% \quad (15)$$

Untuk menghitung sensitivitas kelas D, digunakan persamaan (16) sebagai berikut.

$$\frac{TP}{TP+FN} = \frac{tpD}{tpD+e_{DA}+e_{DB}+e_{DC}} \times 100\% \quad (16)$$

Spesifisitas untuk kelas D dihitung menggunakan persamaan (17) sebagai berikut:

$$\frac{TN}{TN+FP} = \frac{tpA+e_{AB}+e_{AC}+e_{BA}+tpB+e_{BC}+e_{CA}+e_{CB}+tpC}{tpA+e_{AB}+e_{AC}+e_{BA}+tpB+e_{BC}+e_{CA}+e_{CB}+tpC+e_{AD}+e_{BD}+e_{DC}} \times 100\% \quad (17)$$

Akurasi klasifikasi dihitung sebagai rasio antara jumlah *True Positive* (TP) dari seluruh kelas terhadap total keseluruhan data, sebagaimana dinyatakan dalam persamaan (18) berikut:

$$\frac{tpA+tpB+tpC+tpD}{\text{Total Data}} \times 100\% \quad (18)$$

Persamaan (10) hingga (18) menyajikan notasi dan formulasi matematis untuk menghitung sensitivitas, spesifisitas, dan akurasi dalam model klasifikasi empat kelas.

## 5. HASIL DAN PEMBAHASAN

Bagian ini mengevaluasi kinerja sistem klasifikasi katarak dengan metode ekstraksi fitur GLCM dan Filter Gabor serta algoritma jaringan saraf tiruan, yaitu BPNN, PNN, dan RBFNN. Evaluasi dilakukan berdasarkan akurasi, sensitivitas, dan spesifisitas untuk empat klasifikasi katarak, yaitu normal, ringan, sedang, dan berat. Citra retina dari kamera fundus *smartphone* digunakan untuk ekstraksi fitur tekstur pada *optic disc*. Enam kombinasi metode diuji, dan hasilnya menunjukkan bahwa kombinasi Filter Gabor dengan PNN memberikan kinerja terbaik, terutama dalam klasifikasi katarak sedang dan berat, yang menunjukkan efektivitas Filter Gabor dalam mengekstraksi fitur tekstur pada katarak berat. Tabel 4 menunjukkan bahwa kombinasi Filter Gabor dan PNN secara konsisten menghasilkan akurasi pelatihan yang tinggi.

Berdasarkan Tabel 4, hasil perbandingan akurasi pelatihan menunjukkan bahwa Skenario 2 mencatat akurasi tertinggi, yaitu 100% untuk semua kelas. Sebaliknya, Skenario 3, yang menggunakan

GLCM dengan RBFNN, menunjukkan akurasi terendah pada katarak ringan (75%).

Tabel 4. Hasil Perbandingan Akurasi Pelatihan Sistem Klasifikasi Katarak

Skenario	Normal	Mild	Medium	Severe	Sistem
1	100%	87,5%	100%	100%	96,88%
2	100%	100%	100%	100%	100%
3	100%	75%	87,5%	100%	90,63%
4	100%	87,5%	100%	100%	96,88%
5	100%	87,5%	100%	100%	96,88%
6	87,5%	100%	100%	100%	96,88%
<b>Rerata</b>	<b>97,92%</b>	<b>89,58%</b>	<b>97,92%</b>	<b>100%</b>	<b>96,35%</b>

Skenario 1 dan 4, yang menggunakan BPNN, memiliki akurasi rata-rata 96,88%, masih lebih rendah dibandingkan PNN. Secara keseluruhan, akurasi rerata pelatihan mencapai 96,35%, yang menunjukkan efektivitas sistem klasifikasi. Untuk menilai stabilitas model, evaluasi dengan data uji diperlukan, seperti yang ditunjukkan dalam Tabel 5.

Tabel 5. Hasil Perbandingan Akurasi Pengujian Sistem Klasifikasi Katarak

Skenario	Normal	Mild	Medium	Severe	Sistem
1	100%	85,71%	71,43%	71,43%	82,14%
2	100%	100%	71,43%	85,71%	89,29%
3	85,71%	71,43%	42,86%	85,71%	71,43%
4	100%	57,14%	57,14%	100%	78,57%
5	100%	42,86%	85,71%	28,57%	64,29%
6	85,71%	71,43%	71,43%	100%	82,14%
<b>Rerata</b>	<b>95,24%</b>	<b>71,43%</b>	<b>66,67%</b>	<b>78,57%</b>	<b>77,98%</b>

Berdasarkan Tabel 5, hasil perbandingan akurasi pengujian sistem klasifikasi katarak menunjukkan variasi yang signifikan dibandingkan fase pelatihan. Skenario 2 (GLCM dan PNN) mencatat akurasi tertinggi sebesar 89,29%, meskipun akurasi untuk kelas katarak medium hanya 71,43%, yang mengindikasikan tantangan dalam klasifikasi katarak medium akibat kompleksitas fitur citra retina. Skenario 3 (GLCM dan RBFNN) menghasilkan akurasi terendah, yaitu 71,43%, dengan performa kurang memadai pada kelas katarak ringan dan medium, menunjukkan bahwa RBFNN mungkin tidak optimal untuk pola fitur halus dalam citra retina. Sebaliknya, Skenario 1 (GLCM dan BPNN) menunjukkan stabilitas baik dengan akurasi 82,14%, meskipun ada penurunan pada kelas medium dan severe, menandakan kemampuan BPNN dalam mengidentifikasi fitur penting untuk klasifikasi katarak. Skenario 4 dan 5 yang menggunakan Filter Gabor menunjukkan penurunan kinerja signifikan, dengan Skenario 5 mencapai akurasi terendah sebesar 64,29%, mengindikasikan efektivitas GLCM lebih baik dibandingkan Filter Gabor dalam klasifikasi katarak. Rerata akurasi pengujian mencapai 77,98%, mencerminkan potensi sistem klasifikasi meskipun terdapat variasi antar kelas. Hasil sensitivitas disajikan dalam Tabel 6 dan Tabel 7.

Berdasarkan Tabel 6 dan Tabel 7, hasil perbandingan sensitivitas sistem klasifikasi katarak menunjukkan bahwa pada fase pelatihan, Skenario 2

(GLCM dan PNN) mencapai sensitivitas tertinggi, yaitu 100% untuk semua kelas dan rerata 96,88%.

Tabel 6. Hasil Perbandingan Sensitivitas Pelatihan Sistem Klasifikasi Katarak

Skenario	Normal	Mild	Medium	Severe	Rerata
1	100%	87,5%	100%	100%	96,88%
2	100%	100%	100%	100%	100%
3	100%	75%	87,5%	100%	90,63%
4	100%	87,5%	100%	100%	96,88%
5	100%	87,5%	100%	100%	96,88%
6	87,5%	100%	100%	100%	96,88%
<b>Rerata</b>	<b>97,92%</b>	<b>89,58%</b>	<b>97,92%</b>	<b>100%</b>	<b>96,88%</b>

Tabel 7. Hasil Perbandingan Sensitivitas Pengujian Sistem Klasifikasi Katarak

Skenario	Normal	Mild	Medium	Severe	Rerata
1	100%	85,71%	71,43%	71,43%	82,14%
2	100%	100%	71,43%	85,71%	89,29%
3	85,71%	71,43%	42,86%	85,71%	71,43%
4	100%	57,14%	57,14%	100%	78,57%
5	100%	42,86%	85,71%	28,57%	64,29%
6	85,71%	71,43%	71,43%	100%	82,14%
<b>Rerata</b>	<b>95,24%</b>	<b>71,43%</b>	<b>66,67%</b>	<b>78,57%</b>	<b>77,98%</b>

Namun, sensitivitas rerata pada fase pengujian menurun menjadi 77,98%, dengan penurunan paling signifikan pada kelas medium (66,67%). Skenario 3 (GLCM dan RBFNN) mencatat sensitivitas terendah pada kelas medium, yaitu 42,86%, yang menunjukkan tantangan dalam mengidentifikasi pola fitur halus. Skenario 1 (GLCM dan BPNN) tetap stabil dengan sensitivitas 82,14%, meskipun kelas medium turun menjadi 71,43%. Skenario 4 dan 5 menggunakan Filter Gabor menunjukkan variasi, dengan Skenario 5 mencapai sensitivitas 64,29%. Temuan ini mengindikasikan adanya peluang untuk meningkatkan ekstraksi fitur menggunakan Filter Gabor pada data pengujian. Evaluasi spesifisitas akan dibahas lebih lanjut dalam Tabel 8 dan Tabel 9.

Tabel 8. Hasil Perbandingan Spesifisitas Pelatihan Sistem Klasifikasi Katarak

Skenario	Normal	Mild	Medium	Severe
1	95,83%	100%	100%	100%
2	100%	100%	100%	100%
3	95,83%	95,83%	100%	95,83%
4	95,83%	100%	100%	100%
5	95,83%	100%	100%	100%
6	100%	95,83%	100%	100%
<b>Rerata</b>	<b>97,22%</b>	<b>98,61%</b>	<b>100%</b>	<b>99,31%</b>

Pada fase pelatihan, Tabel 8 menunjukkan rerata spesifisitas tinggi sebesar 99,31%. Skenario 2 (GLCM dan PNN) mencatat spesifisitas sempurna 100% untuk semua kelas (normal, ringan, sedang, berat), mencerminkan kemampuan model yang baik dalam membedakan citra positif dan negatif. Skenario lainnya juga mendekati 100%, tetapi Skenario 3 (GLCM dan RBFNN) mengalami penurunan spesifisitas pada kelas normal dan ringan, masing-masing 95,83%, meskipun tetap 100% untuk kelas sedang dan berat. Hasil ini menunjukkan efektivitas model dalam memisahkan citra retina non-katarak dari citra katarak. Tabel 9 menyajikan hasil perbandingan spesifisitas pada fase pengujian sistem

klasifikasi katarak, bertujuan untuk mengevaluasi kemampuan model dalam membedakan citra katarak dari non-katarak setelah pelatihan dan mengidentifikasi stabilitas performa pada berbagai kelas.

Tabel 9. Hasil Perbandingan Spesifisitas Pengujian Sistem Klasifikasi Katarak

Skenario	Normal	Mild	Medium	Severe
1	100%	80,95%	95,24%	100%
2	95,24%	90,48%	100%	100%
3	100%	80,95%	95,24%	85,71%
4	95,24%	90,48%	95,24%	90,48%
5	71,43%	90,48%	95,24%	100%
6	95,24%	85,71%	95,24%	100%
<b>Rerata</b>	<b>92,86%</b>	<b>86,51%</b>	<b>95,24%</b>	<b>96,03%</b>

Berdasarkan Tabel 9, rerata spesifisitas pada fase pengujian menurun menjadi 96,03%, menunjukkan tantangan dalam generalisasi model. Skenario 2 (GLCM dan PNN) mencapai spesifisitas tertinggi, 100% pada kelas sedang dan berat, sedangkan Skenario 5 (Filter Gabor dan PNN) mengalami penurunan signifikan pada kelas normal, dengan nilai 71,43%.

Skenario 1, 3, 4, dan 6 menunjukkan spesifisitas antara 80,95% hingga 100%. Namun, Skenario 3 mengalami penurunan pada kelas berat (85,71%), mencerminkan keterbatasan RBFNN. Meskipun kualitas gambar kamera *fundus smartphone* lebih rendah dibandingkan standar, portabilitas dan biaya yang efisien menjadikannya pilihan yang menjanjikan untuk peningkatan akurasi deteksi melalui pengembangan lebih lanjut.

## 6. KESIMPULAN

Penelitian ini bertujuan untuk mengevaluasi sistem klasifikasi katarak dengan menggunakan metode ekstraksi fitur *Gray-Level Co-occurrence Matrix* (GLCM) dan Filter Gabor, serta algoritma jaringan syaraf tiruan, yaitu *Backpropagation Neural Network* (BPNN), *Probabilistic Neural Network* (PNN), dan *Radial Basis Function Neural Network* (RBFNN). Hasil analisis menunjukkan bahwa pada fase pelatihan, kombinasi Filter Gabor dan PNN mencapai akurasi optimal sebesar 100% untuk seluruh kategori katarak, dengan rerata akurasi pelatihan sebesar 96,35%, sensitivitas 96,88%, dan spesifisitas 97,22%.

Pada fase pengujian, sistem menunjukkan rerata akurasi sebesar 77,98%, dengan sensitivitas yang bervariasi antara 64,29% hingga 89,29%, serta spesifisitas antara 86,51% hingga 96,03%. Temuan ini menunjukkan potensi sistem dalam mendeteksi katarak dengan efektif, meskipun terdapat variasi dalam kinerja antar kategori. Selain itu, hasil menunjukkan bahwa GLCM lebih efektif dalam ekstraksi fitur dibandingkan Filter Gabor pada data uji.

Secara keseluruhan, meskipun terdapat tantangan yang dihadapi, sistem ini menunjukkan potensi yang signifikan dalam deteksi katarak dengan

menggunakan kamera *fundus smartphone*. Pengembangan lebih lanjut pada algoritma dan teknologi pencitraan diharapkan dapat meningkatkan akurasi dan konsistensi sistem dalam aplikasi dunia nyata.

#### DAFTAR PUSTAKA

- AGARWAL, V., GUPTA, V., VASHISHT, V.M., SHARMA, K. AND SHARMA, N., 2019. Mobile Application Based Cataract Detection System. In: *Proceedings of the International Conference on Trends in Electronics and Informatics, ICOEI 2019*. Tirunelveli: IEEE. pp.780–787. <https://doi.org/10.1109/ICOEI.2019.8862774>.
- AHN, S.J. AND KIM, Y.H., 2024. Clinical Applications and Future Directions of Smartphone Fundus Imaging. *Diagnostics*, 14(13), pp.1–16. <https://doi.org/10.3390/diagnostics14131395>.
- ASRIL, B.W., MAISON, M. AND YUDERTHA, A., 2019. Analisis Performa Algoritma Segmentasi Pembuluh Darah pada Citra Fundus Retina. *Jurnal Edukasi dan Penelitian Informatika (JEPIN)*, 5(3), p.272. <https://doi.org/10.26418/jp.v5i3.34416>.
- ASSI, L., CHAMSEDDINE, F., IBRAHIM, P., SABBAGH, H., ROSMAN, L., CONGDON, N., EVANS, J., RAMKE, J., KUPER, H., BURTON, M.J., EHRLICH, J.R. AND SWENOR, B.K., 2021. A Global Assessment of Eye Health and Quality of Life A Systematic Review of Systematic Reviews. *JAMA Ophthalmology*, [online] 139(5), pp.526–541. <https://doi.org/10.1001/jamaophthalmol.2021.0146>.
- CHALAM, K. V., CHAMCHIKH, J. AND GASPARIAN, S., 2022. Optics and Utility of Low-Cost Smartphone-Based Portable Digital Fundus Camera System for Screening of Retinal Diseases. *Diagnostics*, 12(6), p.1499. <https://doi.org/10.3390/diagnostics12061499>.
- DAYA, B., ASMARA, Y., WULANINGRUM, R. AND HELILINTAR, R., 2023. Implementasi Region of Interest (ROI) Untuk Segmentasi Citra Tanda Tangan. In: *Prosiding SEMNAS INOTEK (Seminar Nasional Inovasi Teknologi)*. Kediri: Universitas Nusantara PGRI Kediri. pp.2549–7952. <https://doi.org/https://doi.org/10.29407/inotek.v7i3.3565>.
- DIANTARAKITA. AGUS WAHYU WIDODO. MUHAMMAD ARIF RAHMAN, 2019. Ekstraksi Ciri pada Klasifikasi Tipe Kulit Wajah Menggunakan Metode Local Binary Pattern. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 3(8), pp.7938–7945.
- ELVENY, M., ANJULINA, T., SIREGAR, B. AND SYAH, R., 2020. Identification of Diabetic Retinopathy with Retinal Fundus Imagery Using Probabilistic Neural Network. *Journal of Physics: Conference Series*, 1641(1). <https://doi.org/10.1088/1742-6596/1641/1/012055>.
- FIRDAUS, D.H., IMRAN, B., BAKTI, L.D. AND SURYADI, E., 2022. Klasifikasi Penyakit Katarak Pada Mata Menggunakan Metode Convolutional Neural Network (CNN) Berbasis Web. *Jurnal Kecerdasan Buatan dan Teknologi Informasi (JKBTI)*, 1(3), pp.18–26. <https://doi.org/https://doi.org/10.69916/jkbtiv1i3.6>.
- GAO, Y., YU, X., WU, C., ZHOU, W., WANG, X. AND CHU, H., 2019. Accurate and efficient segmentation of optic disc and optic cup in retinal images integrating multi-view information. *IEEE Access*, 7, pp.148183–148197. <https://doi.org/10.1109/ACCESS.2019.2946374>.
- JUNIATI, D. AND SUWANDA, A.E., 2022. Klasifikasi Penyakit Mata Berdasarkan Citra Fundus Retina Menggunakan Dimensi Fraktal Box Counting Dan Fuzzy K-Means. *Proximal: Jurnal Penelitian Matematika dan Pendidikan Matematika*, 5(1), pp.10–18. <https://doi.org/10.30605/proximal.v5i1.1623>.
- KAMBLE, V. V. AND KOKATE, R.D., 2020. Automated diabetic retinopathy detection using radial basis function. *Procedia Computer Science*, [online] 167(2019), pp.799–808. <https://doi.org/10.1016/j.procs.2020.03.429>.
- MUNARTO, R., PERMATA, E. AND T, I.G.A., 2016. Klasifikasi Glaucoma Menggunakan Cup-To-Disc Ratio Dan Neural Network. In: *Simposium Nasional Ke-15 RAPI 2016*. Surakarta: Universitas Muhammadiyah Surakarta. pp.370–378.
- MUNARTO, R. AND YUDONO, M.A.S., 2019. Klasifikasi Katarak Objek Optic Disc Citra Fundus Retina Menggunakan Support Vector Machine. *Jurnal Ilmiah Setrum*, [online] 8(1), pp.84–95. <https://doi.org/http://dx.doi.org/10.36055/setrum.v8i1.5793>.
- MUNARTO, R., YUDONO, M.A.S. AND PERMATA, E., 2020. Automatic Cataract Classification System Using Neural Network Algorithm Backpropagation. In:

- 2020 *2nd International Conference on Industrial Electrical and Electronics (ICIEE)*. [online] Lombok: IEEE. pp.101–106.  
<https://doi.org/10.1109/ICIEE49813.2020.9277441>.
- RANI, K.C. AND PRASANTH, Y., 2017. A Decision System for Predicting Diabetes using Neural Networks. *IAES International Journal of Artificial Intelligence (IJ-AI)*, 6(2), pp.56–65.  
<https://doi.org/10.11591/ijai.v6.i2.pp56-65>.
- ROHAYA, S. AND HUSNA, C., 2024. Papil Edema. *Detector: Jurnal Inovasi Riset Ilmu Kesehatan*, 2(1), pp.235–242.  
<https://doi.org/https://doi.org/10.55606/detector.v2i1.3347>.
- ROHMAH, S., 2022. Prevalence and Analysis of Risk Factors for Cataracts in Jember Regency, Indonesia. *Sriwijaya Journal Of Ophthalmology*, [online] 5(1), pp.178–189.  
<https://doi.org/https://doi.org/10.37275/sjo.v7i1.117>.
- SKORIN, L. AND NORBERG, S., 2019. The aging crystalline lens: A review of cataracts. *ScienceOpen*, 59(1), pp.0–1.  
<https://doi.org/10.14293/S2199-1006.1.SOR-.PP5CQH9.v1>.
- SPECHT, D.F., 1990. Probabilistic Neural Networks. *Neural Networks*, 3, pp.109–118.  
<https://doi.org/10.1007/s11069-015-1595-z>.
- SWASTIKA, W., 2020. Studi Awal Deteksi Covid-19 Menggunakan Citra Ct Berbasis Deep Preliminary Study of Covid-19 Detection Using Ct Image Based on. *Jurnal Teknologi Informasi dan Ilmu Komputer*, [online] 7(3), pp.629–634.  
<https://doi.org/http://dx.doi.org/10.25126/jtik.2020733399>.
- T, V., M, S., KUMARAVEL, A. AND B, K., 2020. Gabor filter and machine learning based diabetic retinopathy analysis and detection. *Microprocessors and Microsystems*, [online] p.103353.  
<https://doi.org/10.1016/j.micpro.2020.103353>.
- WINTERGERST, M.W.M., JANSEN, L.G., HOLZ, F.G. AND FINGER, R.P., 2020. Smartphone-based fundus imaging - Where are we now? *Asia-Pacific Journal of Ophthalmology*, 9(4), pp.308–314.  
<https://doi.org/10.1097/APO.0000000000000303>.
- YUDONO, M.A.S., HAMIDI, E.A.Z., KUSPRANOTO, A.H. AND SIDIK, A.D.W.M., 2022. Jaringan Syaraf Tiruan Perambatan Balik Untuk Klasifikasi Covid-19 Berbasis Tekstur Menggunakan Orde Pertama Berdasarkan Citra Chest X-Ray. *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, 9(4), pp.799–808.  
<https://doi.org/10.25126/jtik.202295663>.
- YUDONO, M.A.S., ISNANTO, R.R. AND TRIWIYATNO, A., 2021. Comparison of Cataract Classification System Based on Retinal Blood Vessels Objects and Retinal Optic Disc Using Backpropagation Neural Network. *International Journal of Innovations in Engineering and Technology (IJJET)*, 18(2), pp.1–8.  
<https://doi.org/10.13140/RG.2.2.16638.46408>.