

Identifikasi Penyakit Katarak berdasarkan Citra Fundus menggunakan *Siamese Convolutional Neural Network*

RAHMADWATI¹, AZZAM ZAHFRAN IMRAN¹, MUHAMMAD ASWIN¹,
KHAIRUNISA FERDIANA²

¹Departemen Teknik Elektro Universitas Brawijaya Malang, Indonesia

²SMF Mata Rumah Sakit Umum Daerah Kanjuruhan Malang, Indonesia
Email: rahma@ub.ac.id

Received 23 Juli 2024 | Revised 27 September 2024 | Accepted 3 Oktober 2024

ABSTRAK

Katarak merupakan penyakit yang dipengaruhi oleh faktor-faktor tertentu seperti usia, aktivitas dan penderita penyakit genetik seperti diabetes, hipertensi, asam urat serta riwayat keluarga katarak. Diagnosis penyakit katarak ini dapat dipengaruhi oleh faktor subyektif seperti pengalaman dan keahlian dokter. Untuk mengatasi hal tersebut dan menurunkan tingkat subyektivitas diperlukan pendekatan yang akurat dan konsisten yaitu sistem identifikasi penyakit katarak terbantuan komputer. Penelitian ini bertujuan sebagai deteksi dini katarak. Metode SCNN digunakan untuk mengidentifikasi citra fundus mata katarak. Fine tuning parameter SCNN memberikan performa yang baik pada proses pelatihan dan pengujian yaitu 100 epoch, optimizer : RMS Prop dan loss function Binary Crossentropy. Performansi yang diberikan yaitu akurasi 91,25%, kepresisian 91%.

Kata kunci: *penyakit katarak, siamese convolutional neural network, citra fundus.*

ABSTRACT

The cataract is a disease that influenced by certain factors such as age, activity and people with genetic disease such as diabetes, hypertension, uric acid and family history of cataract. The diagnosis of cataracts based on ophthalmologist experience and expertise which signifies a level of a diagnostic subjectivities. In order to overcome that problem and reduce the level of subjectivity, the need for an accurate and consistent computer aided identification for cataract disease is inevitable. This research aims to as an early detection of cataracts. The SCNN is applied for identify the cataract disease based on eye fundus image. Fine tuning SCNN parameters which provide good performances in the training and testing process with 100 epochs, RMSProp optimizer, Binary Crossentropy Loss function. This system gives promising result with the accuracy 91,25% , precision level is 91%.

Keywords: *cataract disease, siamese convolutional neural network, fundus images*

1. PENDAHULUAN

Mata merupakan organ vital pada manusia yaitu sebagai alat penglihatan sehingga sangatlah penting untuk menjaga kesehatan mata. Namun apabila kesehatan mata terabaikan akan mengakibatkan gangguan penglihatan bahkan sampai terjadi kebutaan. Penyakit mata katarak merupakan suatu kondisi dimana kejernihan mata berangsur-angsur mulai berkurang. Katarak merupakan penyakit yang dipengaruhi oleh faktor-faktor tertentu seperti usia, aktivitas, dan juga penderita penyakit genetik yang menunjukkan indikasi dan patologi seperti yang disebabkan diabetes, dehidrasi akut, penyakit atopik, hipertensi, asam urat serta riwayat keluarga katarak (Hamidi, 2017). Di Asia Tenggara, Indonesia memegang peringkat tertinggi penderita kebutaan yaitu 1,5% dimana separonya disebabkan oleh katarak. **(Ramadhani, 2023)**. Penyakit ini dapat disembuhkan dengan jalan operasi, namun deteksi dini sangat penting. Penderita katarak akan memeriksakan dirinya ke dokter untuk mencegah komplikasi dan kehilangan permanen. Kebutuhan akibat katarak dapat disebabkan dokter spesialis mata tidak tersedia di daerah terpencil. Diagnosis penyakit katarak ini juga dapat dipengaruhi oleh faktor subyektif seperti pengalaman dan keahlian dokter. Untuk mengatasi hal tersebut dan menurunkan tingkat subyektifitas diperlukan pendekatan yang akurat dan konsisten yaitu suatu sistem identifikasi penyakit katarak terbantuan komputer (*computer aided identification for cataract disease*).

Beberapa penelitian telah dilakukan mengenai identifikasi penyakit katarak dengan metode *Rule Based Reasoning* dan *Certainty Factor* **(Raenida, 2019)**, *Case Based Reasoning* **(Martono, 2016)**, *Convolutional Neural Network* **(Ramadhani, 2023)** **(Firdaus, 2022)** **(Bu'ulölö, 2021)**, **(Simanjuntak, 2022)**, **(Hasan, 2021)**. Pada penelitian *Rule Based Reasoning* terdapat ketergantungan pada aturan tetap yang membutuhkan pengetahuan domain yang mendalam dan sulit menangani kasus baru yang tidak tercakup dalam aturan. Selain itu, model CNN juga bisa rentan terhadap *overfitting* dan membutuhkan komputasi intensif. Pada penelitian menggunakan CNN yang telah dilakukan sangat bergantung pada kualitas dan kuantitas data yang digunakan untuk pelatihan, sehingga akan mempengaruhi generalisasi dan akurasi dari model yang akan dibangun. Untuk mengatasi hal tersebut maka dilakukan penelitian identifikasi penyakit katarak dengan menggunakan *Siamese Convolutional Neural Network* (SCNN).

Pada penelitian ini membahas identifikasi penyakit katarak menggunakan Kebaruan penggunaan *Siamese Convolutional Neural Network* (SCNN). Dalam mendeteksi penyakit katarak terletak pada kemampuannya untuk mengatasi tantangan spesifik dalam analisis citra medis, terutama dalam kasus di mana data terbatas dan fokusnya adalah mendeteksi perbedaan atau perubahan citra dari waktu ke waktu. Prinsip metode SCNN ini membandingkan dua gambar/citra dimana dapat dipelajari perbedaan dan persamaan antar inputnya sehingga SCNN dapat melakukan identifikasi suatu objek dengan efektif. Pada proses pelatihan data yang dibutuhkan tidak banyak, dimana model dapat belajar dengan baik dengan menggunakan sedikit data yang berpasangan (*paired data*) dimana tidak ditemukan pada jaringan syaraf tiruan yang lain. Pada saat pelatihan. SCNN mempelajari metrik kesamaan antara input. Arsitektur SCNN ini dapat dimodifikasi sehingga memungkinkan penerapannya pada berbagai bidang. SCNN merupakan teknologi yang terus berkembang dan memiliki potensi besar untuk berbagai aplikasi.

Penelitian ini bertujuan untuk membangun suatu sistem identifikasi katarak terbantu komputer dengan menggunakan metode *Siamese Convolutional Neural Network* sebagai *deteksi dini katarak dengan memperhatikan perubahan kecil pada lensa mata* serta mengurangi subyektivitas dalam pemeriksaan. *Hal ini sangat penting karena katarak yang dideteksi lebih*

awal bisa dirawat dengan lebih baik, sehingga mengurangi risiko kehilangan penglihatan permanen. Terlepas dari tantangan-tantangan ini, penelitian dan pengembangan yang sedang berlangsung dalam identifikasi katarak berbasis SCNN memiliki potensi besar untuk meningkatkan deteksi dini, memfasilitasi intervensi tepat waktu, dan meningkatkan kualitas pelayanan pada pasien.

2. METODE

2.1 Convolutional Neural Network

Convolutional Neural Network (CNN), dikenal sebagai jaringan konvolusional, merupakan jenis jaringan saraf yang dirancang khusus untuk memproses data dengan topologi grid yang serupa (Andika, 2019). CNN merupakan algoritma *deep learning* dan mempunyai beberapa proses yang terdiri dari proses konvolusi, proses aktivasi, proses *pooling* dan proses *fully connected*. Adapun beberapa proses pada CNN sebagai berikut :

Pada tahap ini lapisan konvolusi, operasi konvolusi dilakukan oleh data input dan kernel. Kernel dari CNN merupakan *array* multidimensi yang akan menjadi operator untuk melakukan operasi tertentu dengan *array* input. Nilai pada kernel merupakan nilai yang diperoleh dari hasil pelatihan. Hasil dari operasi antara input dan kernel dinamakan dengan map fitur (peta ciri). Perhitungan pada lapisan konvolusi dapat dilakukan menggunakan Persamaan (1)

$$(f * g)(x, y) = \sum_{a=x-h}^{x+h} \sum_{b=y-w}^{y+h} f(a, b)g(x - a, y - b) \quad (1)$$

Fungsi $f(x,y)$ adalah fungsi citra input sedangkan $g(x,y)$ adalah kernel konvolusi atau kernel filter. Kernel $g(x,y)$ merupakan *window* yang dioperasikan dengan pola bergeser pada citra input, dimana hasil perkalian kedua fungsi pada setiap titik merupakan hasil konvolusi yang dinyatakan sebagai fungsi output $h(x,y)$

Proses kedua adalah lapisan aktivasi yang menggunakan *Rectified Linear Unit (ReLU)*. Fungsi ini merupakan fungsi aktivasi yang sangat umum digunakan pada jaringan syaraf tiruan. Persamaan 2 digunakan untuk mengenali elemen ketidak linearan dalam jaringan syaraf tiruan.

$$\text{ReLU}(x) = \max(0, x) \quad (2)$$

Berikutnya lapisan *pooling*, lapisan ini mereduksi dimensi array input yang masuk dengan memaksimalkan, menjumlah atau meratakan yang dinamakan dengan *maxpooling*, *sum pooling* atau *average pooling*. Pada penelitian ini menggunakan *maxpooling*. *Max pooling* merupakan jenis *pooling* yang umum digunakan yang mengambil nilai maksimum dari setiap operasi kernel pada input. Output pada tahap ini menghasilkan dimensi data yang lebih kecil tetapi tanpa mengeleminasi informasi penting dari data yang diterima. Pada Persamaan 3 merupakan rumus untuk menghitung *maxpooling*.

$$f_{\max}(x) = \max \{x_i\}_i^N = 1 \quad (3)$$

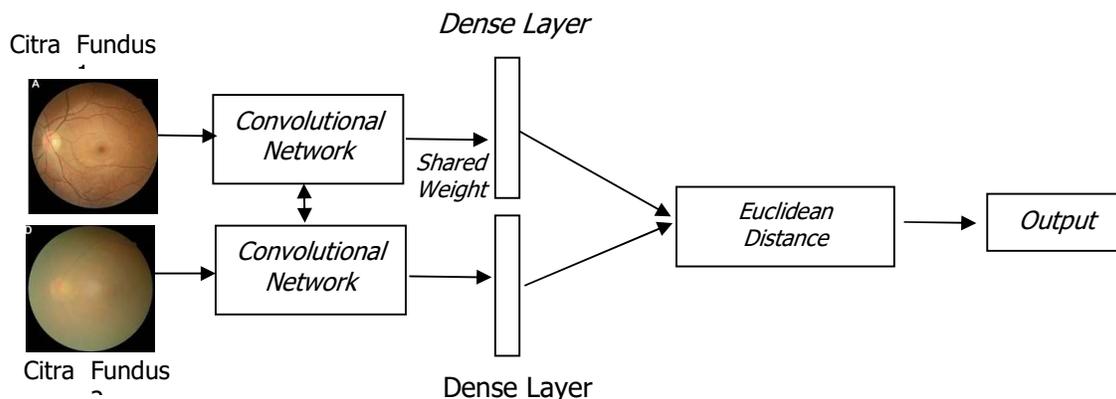
Fungsi aktivasi adalah fungsi yang digunakan pada neural network untuk mengaktifkan atau menonaktifkan sebuah *neuron* (Putra, 2019). Fungsi aktivasi ini bekerja dengan cara mengubah jumlah masukan berbobot dari sebuah *neuron* menjadi keluaran untuk dimasukkan ke dalam lapisan tersembunyi berikutnya atau sebagai keluaran. Fungsi aktivasi secara khusus digunakan untuk mengenali pola kompleks pada data karena jika tidak digunakan maka *output layer* hanya akan menjadi fungsi linear sederhana yang mengakibatkan model tidak memiliki

kemampuan untuk mempelajari dan mengenali pemetaan kompleks dari data (**Sianturi, 2023**). Oleh karena itu, dengan adanya fungsi aktivasi maka jaringan akan mengenali sifat non-linearitas sehingga memungkinkan model untuk mempelajari hubungan yang lebih kompleks. Adapun fungsi aktivasi yang biasanya digunakan dalam *neural network* adalah *Rectified Linear Unit* (ReLU) yang di mana jika elemen bernilai negatif maka nilai diset menjadi 0 seperti pada Persamaan 4.

$$f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (4)$$

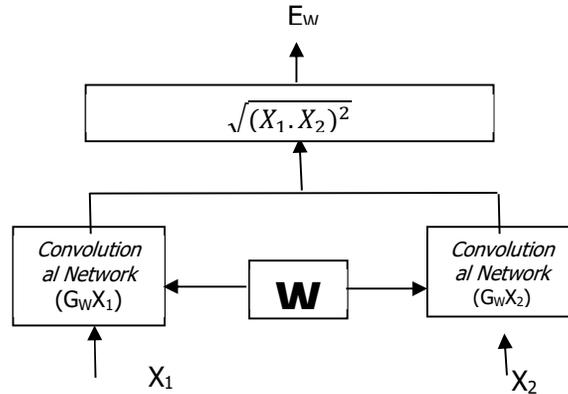
Tuning hyperparameter dilakukan sebelum proses pelatihan, hal ini dilakukan agar sistem dapat memberikan performansi yang baik. Adapun sebuah *hyperparameter tuning* merupakan sebuah proses penentuan *hyperparameter* yang optimal untuk sebuah model pembelajaran (**Naufal, 2022**). Contoh dari *Hyperparameter* menurut (**Aristyanto, 2021**) antara lain *epoch, batch, split, learning rate, activation function, Optimizer* dan jumlah *layer*.

2.2 *Siamese Convolutional Neural Network*



Gambar 1. Arsitektur *Siamese Convolutional Neural Network*

Pada Gambar 1 menunjukkan arsitektur *Siamese Convolutional Neural Network* (SCNN) yaitu jaringan syaraf tiruan untuk mencocokkan atau membandingkan dua input citra. Arsitektur terdiri dari dua *Convolutional Neural Network* yang identik dimana mempunyai dua input yang berbeda yang terhubung dengan lapisan output bersama. Input sistem merupakan pasangan citra yang salah satunya telah diberi label kemudian digunakan untuk mempelajari metrik kesamaan dengan cara melatih CNN yang mempunyai bobot identik. Masing-masing CNN memproses satu input data secara terpisah, menghasilkan representasi fitur dari setiap input. Representasi fitur ini akan digabungkan dan diolah oleh lapisan output untuk menghasilkan skor kemiripan yang menunjukkan seberapa mirip kedua input data. SCNN ini menggunakan CNN untuk mendapatkan hasil yang baik untuk pengenalan gambar (**Laynardi, 2022**). Pasangan input untuk proses pelatihan yaitu X_1 dan X_2 dapat dilihat pada Gambar 2 sebagai berikut (**Chopra, 2005.**).



Gambar 2. Euclidean distance pada Siamese Convolutional Neural Network

Output dari SCNN merupakan bilangan biner jika $E_w=0$ berarti pasangan kedua citra fundus adalah berbeda kategori, sedangkan $E_w=1$ adalah memiliki kategori yang sama. Bobot dibagi (*shared weight*) antara jaringan SCNN dengan cara memetakan pola pasangan input dan mengekstraksi ciri utama yang nantinya akan dibandingkan di akhir proses. *Euclidean distance* digunakan untuk mengukur jarak kemiripan pada *output* dari masing-masing jaringan CNN menggunakan Persamaan 4. (Santos, 2024).

$$E_w(X_1 X_2) = \sqrt{\sum_{u=0}^n (G_w(X_1) - G_w(X_2))^2} \quad (4)$$

E_w = *Euclidean Distance*

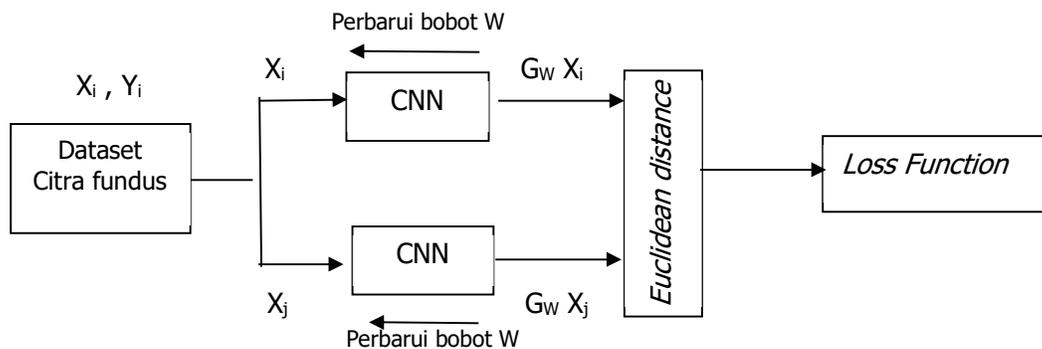
G_w = Keluaran CNN

X_1, X_2 = citra input

W = bobot

2.3 Proses Pelatihan

Pada tahap pelatihan model SCNN ini terdiri dari dua CNN yang arsitektur, konfigurasi dan bobot yang identik. Selama pelatihan parameternya diperbarui secara simultan dengan bobot yang sama.



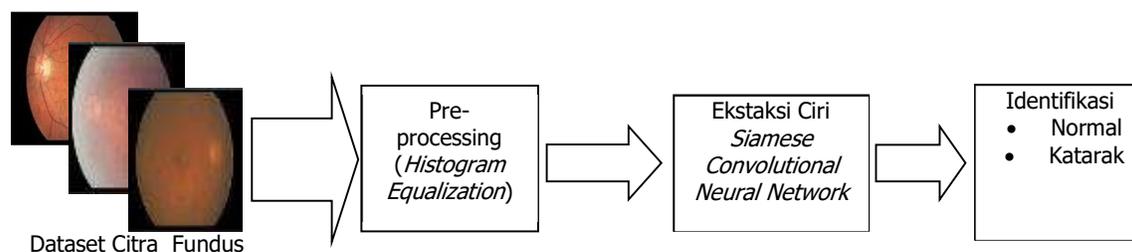
Gambar 3. Proses Pelatihan

Pada Gambar 3 menunjukkan proses pelatihan: X_i, Y_i merupakan data set citra fundus yang sudah berlabel yang akan dilatih, W merupakan bobot, G_w adalah output dari CNN, E_w adalah *Euclidean distance* yang akan dihubungkan dengan nilai output masing-masing pengekstraksi ciri (CNN).

Identifikasi Penyakit Katarak berdasarkan Citra Fundus menggunakan *Siamese Convolutional Neural Network*

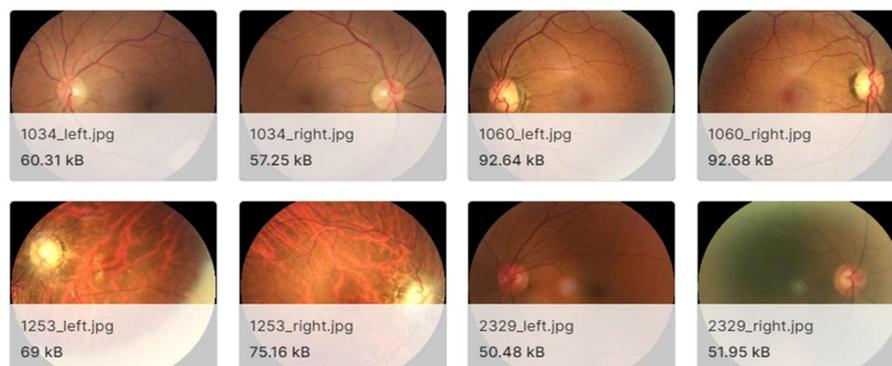
Proses pelatihan sebagai berikut : (1) Citra fundus i (X_i) melalui jaringan *convolutional* dan *fully connected layer* untuk mendapatkan vektor yang merupakan representasi citra $G_w(X_i)$; (2) Citra fundus j (X_j) juga melalui tahap yang sama seperti pada no 1 sehingga mendapatkan vektor $G_w(X_j)$; (3) Kemudian dilakukan perbandingan jarak dengan menggunakan *Euclidean distance*. Jika E_w kecil (mendekati 0) maka diperoleh pasangan yang mirip, tetapi jika E_w besar (mendekati 1) berarti tidak mirip; (4) Pada penelitian ini menggunakan tiga jenis *loss function* yaitu *Binary Crossentropy*, *Mean Squared Error* (MSE) dan *Mean Absolute Error* (MAE) ; (5) Propagasi balik dilakukan untuk menghitung gradien model; (6) Perbarui bobot menggunakan *optimizer* untuk meminimalisasi *loss*; (7) Proses ini diulang sampai bobot nya konvergen ($W_i=W_j$) atau sampai dengan mencapai *epoch* yang telah ditetapkan.

Pada Gambar 4 menunjukkan diagram alir sistem identifikasi penyakit katarak berdasarkan Citra fundus menggunakan *Siamese Convolutional Neural Network*.

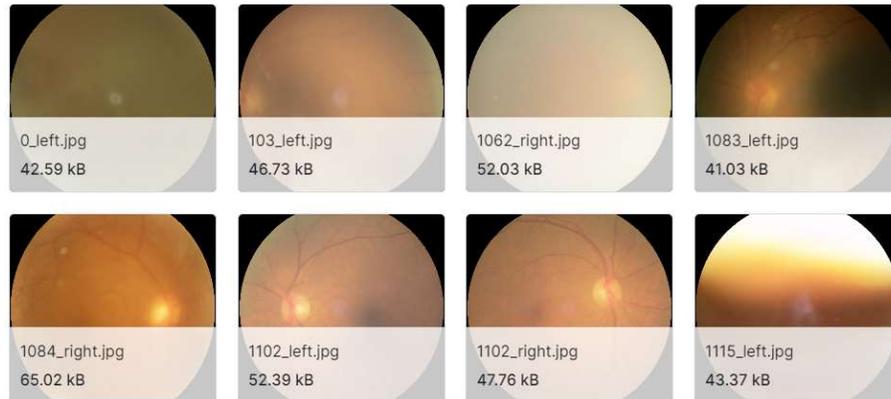


Gambar 4. Sistem Identifikasi Penyakit Mata Katarak berdasarkan Citra fundus menggunakan *Siamese Convolutional Neural Network*

Data set Citra fundus yang digunakan pada penelitian ini merupakan open dataset yang disediakan oleh Kaggle yang dibuat oleh Gunna Rohan Darji terdiri dari citra mata normal dan mata yang terkena katarak. Jumlah data yang digunakan adalah 2000 citra berwarna dengan ukuran 224 x 224 pixel yang dibagi untuk data pelatihan dan data uji. Citra mata normal ditunjukkan pada Gambar 5 dan Citra mata katarak ditunjukkan pada Gambar 6 dimana masing-masing citra sudah diberi label.



Gambar 5. Citra Fundus Mata Normal



Gambar 6. Citra Fundus Mata Katarak

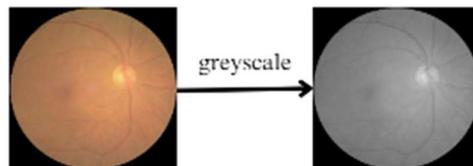


Gambar 7. Mata Normal dan Terkena Katarak

Gambar 7 menunjukkan *Region of interest* citra fundus mata normal dan mata katarak. Pada citra fundus normal (kiri), terlihat jelas disk optik, pembuluh darah, dan makula tanpa adanya kelainan. Sementara itu, pada citra fundus dengan katarak (kanan), terlihat kekeruhan atau kabut di sekitar area lensa, yang menyebabkan detail retina menjadi kurang jelas dan kabur.

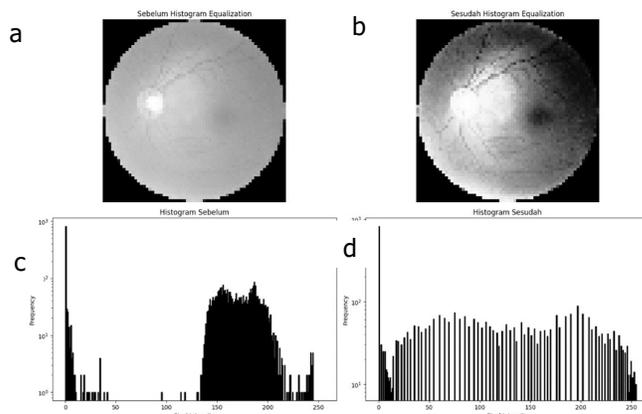
2.4 Pre-processing

Data yang ada dibagi menjadi data latih dan data uji. Citra berwarna sebelumnya akan ditransformasikan ke dalam citra *grayscale* seperti ditunjukkan pada Gambar 8.



Gambar 8. Citra berwarna di transformasikan menjadi citra Grayscale (keabuan)

Untuk meningkatkan kualitas citra maka dilakukan pro-prosesing yaitu *Histogram Equalization*. Pada Gambar 9 menunjukkan citra hasil *pre processing*. Histogram citra sebelum dilakukan operasi *histogram equalization* terlihat penyebaran tidak merata pada distribusi intensitas nya, tetapi setelah dilakukan *histogram equalization* terlihat distribusi intensitas warnanya lebih merata sehingga informasi penting yang terkandung pada citra fundus tidak hilang seperti struktur lensa mata dan kualitas citra semakin baik sehingga mudah dikenali oleh model.



Gambar 9 (a) Citra Asli (b) Citra yang telah di perbaiki dengan *Histogram Equalisation* (c) Histogram Citra Asli (d) Histogram Citra yang telah dilakukan perbaikan.

2.5 Perancangan Sistem

Convolutional Neural Network merupakan bagian dari perancangan sistem identifikasi mata katarak. Pada penelitian ini menggunakan library *Python*. *Batch size* yang digunakan adalah 32 dan 25,50 dan 100 *epoch*, serta *batch* normalisasi untuk mendapatkan model menjadi lebih cepat dan stabil. Pada Tabel 1 menunjukkan parameter yang digunakan pada sistem ini.

Tabel 1. Parameter CNN yang digunakan pada Sistem Identifikasi

Parameter	Nilai
Batch	32
Epoch	25,50,100
Learning rate	0.001
Optimizer	<i>RMS Prop, SGD, NAdam</i>
Fungsi Aktivasi	RELU
Loss Function	<i>Binary Cross entropy, Mean Squared Error (MSE) dan Mean Absolute Error (MAE).</i>

Pada *Siamese Convolutional Neural Network* ini menggunakan dua buah CNN yang digunakan untuk ekstraksi Ciri. Adapun Model CNN dapat dilihat pada Tabel 2. Output dari masing-masing CNN digabungkan kemudian dihitung kemiripannya menggunakan *Euclidean distance* yang ditunjukkan model SCNN pada Tabel 3.

Tabel 2. Model CNN yang digunakan pada Sistem Identifikasi

Proses Ke-	Proses Yang terjadi
1	<code>l2_reg = l2(1e-4)</code>
2	<code>inputs = Input((64, 64, 1))</code>
3	<code>Conv2D(16, (3, 3), padding="same", activation="relu", kernel_regularizer=l2_reg)</code>
4	<code>MaxPooling2D(pool_size=(2, 2))</code>
5	<code>BatchNormalization()</code>
6	<code>Dropout(0.2)</code>
7	<code>Conv2D(32, (3, 3), padding="same", activation="relu", kernel_regularizer=l2_reg)</code>
8	<code>MaxPooling2D(pool_size=(2, 2))</code>
9	<code>BatchNormalization()</code>
10	<code>Dropout(0.2)</code>
11	<code>Conv2D(64, (3, 3), padding="same", activation="relu", kernel_regularizer=l2_reg)</code>
12	<code>MaxPooling2D(pool_size=(2, 2))</code>
13	<code>BatchNormalization()</code>
14	<code>Dropout(0.2)</code>
15	<code>Conv2D(128, (3, 3), padding="same", activation="relu", kernel_regularizer=l2_reg)</code>
16	<code>MaxPooling2D(pool_size=(2, 2))</code>
17	<code>BatchNormalization()</code>
18	<code>Dropout(0.2)</code>
19	<code>GlobalAveragePooling2D()</code>
20	<code>Dense(2048, activation="relu", kernel_regularizer=l2_reg)</code>
21	<code>Dropout(0.55)</code>
22	<code>Dense(128, activation="relu", kernel_regularizer=l2_reg)</code>

Tabel 3. Model *Siamese Convolutional Neural Network*

Proses Ke-	Proses Yang terjadi
1	<code>feature_extractor = create_model()</code>
2	<code>imgA = Input(shape=(64, 64, 1))</code>
3	<code>imgB = Input(shape=(64, 64, 1))</code>
4	<code>featA = feature_extractor(imgA)</code>
5	<code>featB = feature_extractor(imgB)</code>
6	<code>def euclidean_distance(vectors): (featureA, featureB) = vectors sum_squared = k.sum(k.square(featureA - featureB), axis=1, keepdims=True) return k.sqrt(k.maximum(sum_squared, k.epsilon()))</code>
7	<code>distance = Lambda(euclidean_distance)([featA, featB])</code>
8	<code>outputs = Dense(1, activation="sigmoid")(distance)</code>
9	<code>model = Model(inputs=[imgA, imgB], outputs=outputs)</code>

Pada penelitian ini tuning arsitektur, parameter dan hyperparameter dilakukan oleh peneliti sehingga diperoleh hasil yang terbaik.

3. HASIL DAN PEMBAHASAN

Data yang digunakan pada penelitian ini sebagai data latih yaitu sejumlah 1200 sedangkan jumlah data uji 400. Pada penelitian ini menggunakan beberapa percobaan terkait *fine tuning*

hyperparameter yang meliputi jumlah *epoch*, *optimizer* dan *loss function*. Pada penelitian ini, digunakan 25, 50, dan 100 *epoch*. Variasi ini dipilih untuk menemukan titik optimal pelatihan: 25 *epoch* untuk evaluasi awal performa, 50 *epoch* untuk memastikan model terus belajar dengan baik, dan 100 *epoch* untuk memastikan pelatihan maksimal tanpa *overfitting*. Sehingga dapat ditentukan jumlah iterasi terbaik untuk keseimbangan antara akurasi dan validasi model.

Tabel 4. Hasil pelatihan dan validasi dengan *Epoch* bervariasi

<i>Epoch</i>	<i>Train</i>		<i>Validation</i>	
	<i>Accuracy</i>	<i>Loss</i>	<i>Accuracy</i>	<i>Loss</i>
25	0,7065	0,6218	0,6525	0,6879
50	0,8780	0,3695	0,7975	0,4918
100	0,9910	0,1958	0,9000	0,3057

Pada Tabel 4 diperlihatkan bahwa pada *epoch* ke-100, model mencapai performa terbaik dengan akurasi yang sangat tinggi dan *loss* yang sangat rendah, baik pada data pelatihan maupun validasi dengan nilai akurasi 0,9910 untuk akurasi pelatihan dan 0,9000 untuk akurasi validasi. Akurasi ini menunjukkan bahwa dengan jumlah *epoch* yang tepat, model SCNN dapat mencapai performa optimal dalam mengidentifikasi katarak, dengan bertambahnya *epoch* akurasi semakin meningkat serta menunjukkan bahwa pada semua ragam *epoch* model tidak mengalami *overfitting*. Pada penelitian ini menggunakan tiga jenis *optimizer* berbeda yang diterapkan pada arsitektur model yang sama untuk memperoleh jenis *optimizer* yang terbaik dalam pendeteksian penyakit katarak. *Optimizer* yang digunakan meliputi Nadam, RMSProp, dan SGD dan hasilnya terlihat pada Tabel 5.

Tabel 5. Hasil penerapan tiga jenis *optimizer*

<i>Optimizer</i>	<i>Train</i>		<i>Validation</i>	
	<i>Accuracy</i>	<i>Loss</i>	<i>Accuracy</i>	<i>Loss</i>
Nadam	0,9732	0,2489	0,8750	0,3611
SGD	0,9868	0,1264	0,8650	0,5040
RMSProp	0,9910	0,1958	0,9000	0,3057

Optimizer RMSProp menunjukkan performa terbaik dalam pengujian model SCNN untuk identifikasi katarak, dengan akurasi tertinggi dan *loss* terendah pada data validasi. RMSProp menggunakan *adaptive learning rates* yang menyesuaikan laju pembelajaran berdasarkan rata-rata kuadrat gradien sebelumnya, membantu mengatasi masalah *vanishing* dan *exploding gradients*. Ini sangat penting untuk *dataset* katarak yang kompleks dan bervariasi dalam pencahayaan dan kontras.

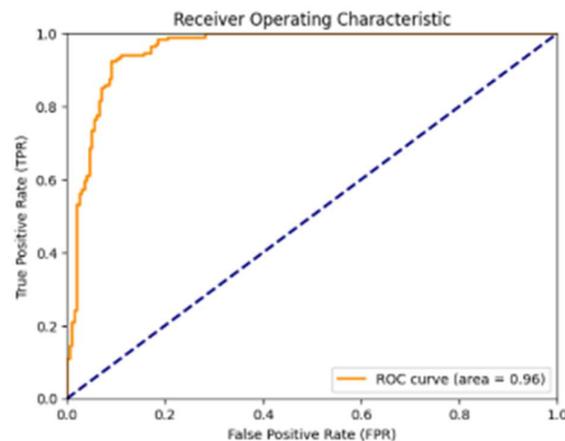
Terdapat tiga *loss function* yang digunakan pada penelitian ini untuk mendapatkan performansi yang terbaik. Jenis *loss function* meliputi *Binary Cross entropy*, *Mean Squared Error* (MSE) dan *Mean Absolute Error* (MAE). Terlihat pada Tabel 6 hasil *testing* dan *validation accuracy* dari penggunaan jenis *Loss Function* yang berbeda.

Tabel 6 Hasil testing dan *validation accuracy* dari penggunaan jenis *Loss Function* yang berbeda.

<i>Loss Function</i>	<i>Train</i>		<i>Validation</i>	
	<i>Accuracy</i>	<i>Loss</i>	<i>Accuracy</i>	<i>Loss</i>
<i>Binary Crossentropy</i>	0,9910	0,1958	0,9000	0,3057
MSE	0,9823	0,0609	0,8700	0,1266
MAE	0,9721	0,1958	0,6871	0,3865

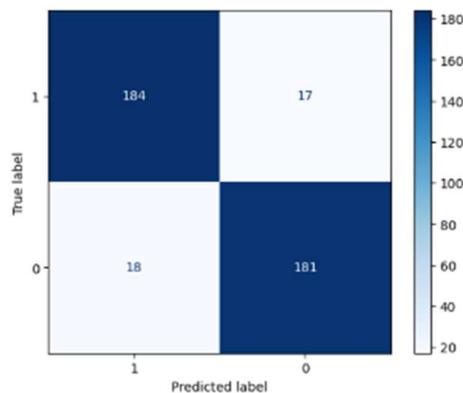
Binary Crossentropy menunjukkan performa terbaik pada model SCNN untuk identifikasi katarak karena lebih sesuai dengan karakteristik *dataset* biner, seperti mendeteksi adanya katarak (positif) atau tidak (negatif). Teknik ini efektif dalam menangani probabilitas output, memastikan bahwa model dapat mengidentifikasi perbedaan kecil dalam citra mata dengan lebih akurat. *Binary Crossentropy* memperbarui bobot lebih efisien berdasarkan *log loss*, yang sangat penting untuk dataset katarak yang memiliki variasi tinggi dalam pencahayaan dan kontras. Akibatnya, model dapat belajar pola yang relevan dengan lebih baik, meningkatkan akurasi dan mengurangi loss pada data validasi.

Untuk mengevaluasi performa model SCNN dalam mengidentifikasi kelainan mata katarak, dilakukan serangkaian pengujian yang melibatkan berbagai metrik dan teknik analisis. Pengujian ini bertujuan untuk memastikan bahwa model tidak hanya mampu mengenali pola pada data pelatihan tetapi juga dapat menggeneralisasi dengan baik pada data baru. Tiga aspek utama yang dibahas dalam pengujian ini meliputi analisis berdasarkan kurva *Receiver Operating Characteristic* (ROC dan evaluasi keseluruhan performa sistem menggunakan *confusion matrix*).



Gambar 10. Kurva ROC

Pada Gambar 10 terlihat bahwa area di bawah kurva adalah 0.96, yang menunjukkan bahwa model memiliki kemampuan yang sangat baik dalam membedakan antara mata yang sehat dan yang terkena katarak. Semakin mendekati 1, semakin baik performa model dalam mengidentifikasi kondisi yang berbeda. *ROC curve* ini menunjukkan bahwa model SCNN mampu memberikan tingkat deteksi yang tinggi dengan sedikit *False Positives*.



Gambar 11. Confussion Matrix

Pada Gambar 10 menunjukkan *Confusion Matrix* yang ditampilkan untuk menunjukkan hasil pengujian model SCNN dengan empat komponen utama: *True Positives* (TP), *True Negatives* (TN), *False Positives* (FP), dan *False Negatives* (FN). Dapat disimpulkan model berhasil mengidentifikasi 184 kasus positif katarak dengan benar (TP) dan 181 kasus negatif katarak dengan benar (TN). Namun, terdapat 17 kasus positif yang salah diidentifikasi sebagai negatif (FN) dan 18 kasus negatif yang salah diidentifikasi sebagai positif (FP).

Tabel 7. Performansi Sistem

Jenis	Akurasi	Presisi	Recall	F1-Score
Katarak	0,9125	0,911	0,915	0,913
Waktu Prediksi (400 citra)	0,1113			

Pada Tabel 7 diperlihatkan bahwa model dapat mengidentifikasi mata katarak dengan akurasi sebesar 0,9125, presisi sebesar 0,911, *recall* sebesar 0,915, dan *F1-Score* sebesar 0,913. Akurasi mengukur proporsi prediksi yang benar dari keseluruhan prediksi, presisi mengukur proporsi prediksi positif yang benar dari semua prediksi positif, *recall* mengukur proporsi positif yang benar teridentifikasi dari semua kasus positif sebenarnya, dan *F1-Score* adalah rata-rata harmonis dari presisi dan *recall*. Adapun model dapat melakukan prediksi pada 400 citra dengan waktu 0,1113 detik. Akurasi mengukur proporsi prediksi yang benar dari keseluruhan prediksi, presisi mengukur prediksi positif yang benar dari semua prediksi positif, *recall* mengukur proporsi positif yang benar teridentifikasi dari semua kasus positif sebenarnya, dan *F1-score* adalah rata-rata harmonis dari presisi dan *recall*. Hasil pengujian ini menunjukkan bahwa model SCNN memiliki kemampuan yang baik dalam mengidentifikasi kelainan mata katarak, dengan tingkat kesalahan yang relatif rendah.

4. KESIMPULAN

Sistem identifikasi penyakit katarak berdasarkan citra fundus menggunakan *Siamese Convolutional Neural Network* dapat bekerja dengan baik. Performansi sistem ini memberikan akurasi 91,25%, tingkat kepresisian yaitu 91%. dan mampu mengolah serta memprediksi 400 citra dalam 0,1113 detik. *Fine tuning* parameter SCNN yang memberikan performa yang baik pada proses pelatihan maupun testing (pengujian) yaitu dengan 100 *epoch*, *Optimizer RMSProp*, *Loss function Binary Crossentropy*. Model yang digunakan ini diharapkan dapat diterapkan pada kasus pengenalan atau identifikasi penyakit lainnya dengan obyek yang berbeda.

DAFTAR RUJUKAN

- Andika, L. A. (2019). Klasifikasi Penyakit Pnemunia Menggunakan Metode Convolutional Neural Network dengan Optimasi Adaptive Momentum. *Indonesia Journal of Satatistic and Its Application*, 3(3).
- Aristyanto, M. Y. (2021). Pengembangan Metode Neural Machine Translation Berdasarkan Hyperparameter Neural Network. Seminar Nasional Official Statistics,.
- Arnstein, S. R. (1969). A Ladder of Citizen Participation. In R. T. Gates, & F. Stout (Eds.), *The City Reader* (2nd ed.). New York: Routledge Press.

- Borer, M. I. (2010). From Collective Memory to Collective Imagination: Time, Place, and Urban Redevelopment. *Symbolic Interaction*, 33(1), 96-144.
- Bu'ulölö, G. J. (2021). Identification of Cataract Eye Disease Using Convolutional Neural Network. *Jurnal Teknik Informatika*, 16(4), 375-382.
- Chopra S, , R. (2005.). Learning a similarity metric discriminatively, with application to face verification. 1. *Proceedings of the 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*.
- Darlis, A. R. (2015). Impementation Visible Light Communication. *International Optical Conference* (pp. 200 - 209). Bandung: Institut Teknologi Nasional Bandung.
- Firdaus, D. H. (2022). Klasifikasi Penyakit Katarak Berdasarkan Citra Menggunakan metodo CNN Berbasis Web. *Jurnal Kecerdasan Buatan dan Teknologi Informasi*, 1(3), 18-26.
- Hamidi, .. M. (2017). Faktor-faktor Yang Berhubungan Dengan Terjadinya Katarak Senilis Pada Pasien Di Oli RSUD Bangkinang. *J.Ners Univ Pahlawan Tuanku TAmbusai*, 1(1), 125-136.
- Hasan, M. K. (2021). Cataract Disease Detection by Using Transfer Learning-Based Intelligent Methods. *Computational and Mathematical Methods in Medicine*, 11(1), 1-11.
- Laynardi, F. (2022). *Implementasi Siamese Convolutional Neural Network untuk Masked Face Recognition*. Bachelor Thesis thesis, Universitas Multimedia Nusantara.
- Martono, G. H. (2016). Diagnosa Penyakit Katarak Senilis Dengan Menggunakan Case Based Reasoning(CBR) Berbasis Web. *Seminar Nasional Teknologi Informasi dan Multimedia STMIK AMIKOM*, (pp. 3.6-6.1-3.6-6.6.).
- Naufal, M. F. (2022). Analisis Sentimen pada Media Sosial Twitter Terhadap Kebijakan Pemberlakuan Pembatasan Kegiatan Masyarakat Berbasis Deep Learning. *Jurnal Edukasi dan Penelitian Informatika*, 8(1), 44-49.
- Poston, J. D., & Bouvier, L. F. (2010). *An Introduction to Demography*. Cambridge: Cambridge University Press.
- Putra, K. ,. (2019). Pengenalan Simbol Matematika dengan Metode Convolutional Neural Network (CNN). *Jurnal Strategi*, 2(2), 426-433.
- Raenida, R. Z. (2019). Sistem Pakar Diagnosis Dini Penyakit Katarak Menggunakan Metode Rule Based Reasoning. Seminar Nasional Informatika Medis (SNIMed) 2019.
- Ramadhani, F. A. (2023). . Implementasi Algoritma Convolutional Neural Network dalam Mengidentifikasi Dini Penyakit pada Mata Katarak. *Jurnal Teknik Informatika,,* 2(4), 167-175.

Identifikasi Penyakit Katarak berdasarkan Citra Fundus menggunakan *Siamese Convolutional Neural Network*

- Santos, M. S. (2024). Predicting diabetic retinopathy stage using Siamese Convolutional Neural Network. *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, 12(1), 1-13.
- Sianturi, B. T. (2023). Penerapan Algoritma Long Short-Term Memory (LSTM) berbasis Multi Fungsi Aktivasi Terbobot dalam Prediksi Harga Ethereum. *Jurnal Pengembangan Teknologi Informasi dan Komputer*.
- Simanjuntak, R. B. (2022). Cataract Classification Based on Fundus Images Using Convolutional Neural Network. *International Journal on Informatic and Visualization*, 6(1).