

Identification of Cataract Eye Disease Using Convolutional Neural Network

Identifikasi Citra Penyakit Mata Katarak Menggunakan *Convolutional Neural Network*

Geza Jeremia Bu'ulölö, Agustinus Jacobus, Feisy D. Kambey

Teknik Elektro Universitas Sam Ratulangi Manado, Jl. Kampus Bahu-Unsrat Manado, 95115, Indonesia

E-mails: 17021106040@student.unsrat.ac.id, a.jacobus@unsrat.ac.id, feisykambey@unsrat.ac.id

Received: 9 June 2021; revised: 15 July 2021; accepted: 15 July 2021

Abstract — *Cataract is a blindness disease that affects the progressive function of eye clarity. At least 50% of blindness cases are caused by cataracts. In the development of the era, of course, image processing information technology is one of the solutions in meeting a need. In this case, we need a system that can identify cataracts. Convolutional Neural Network architecture is part of deep learning. With this architecture, biological processes have a pattern of connectivity between neurons resembling the visual cortex. The output of this architecture is in the form of predictions for identification in an image of a cataract eye and an image of a normal eye. Based on testing of the system on a web-based application, the system that was built succeeded in identifying cataract eye images and normal eye images with test data as much as 30% of the training data. From the tests carried out on parameter values and tests on the optimizer on the Convolutional Neural Network architecture method, the accuracy results are 91.41% on the RMSProp optimizer, 92.93% on the Adam optimizer, 81.56% on the SGD optimizer, and 68.65% on the AdaDelta optimizer.*

Keywords — *Cataract Eye Image; Deep Learning; Convolutional Neural Networks; Optimizer.*

Abstrak – Katarak merupakan salah satu penyakit kebutaan yang mempengaruhi fungsi progresif pada kejernihan mata. sedikitnya 50% kasus kebutaan diakibatkan oleh katarak. Dalam berkembangnya zaman, tentunya teknologi informasi pengolahan citra merupakan salah satu yang menjadi solusi dalam memenuhi suatu kebutuhan. Dalam hal ini, diperlukan sebuah sistem yang dapat melakukan identifikasi terhadap penyakit katarak. Arsitektur *Convolutional Neural Network* merupakan bagian dari *deep learning*. Dengan arsitektur ini memiliki proses biologi yang memiliki pola konektivitas antar *neurons* menyerupai korteks visual. Dalam hasil keluaran dari arsitektur ini berupa prediksi untuk identifikasi pada suatu citra mata katarak maupun citra mata normal. Berdasarkan pengujian terhadap sistem pada aplikasi berbasis web, sistem yang dibangun berhasil mengidentifikasi citra mata katarak dan citra mata normal dengan data uji sebanyak 30% dari data pelatihan. Dari pengujian yang dilakukan terhadap nilai parameter dan pengujian terhadap *optimizer* pada metode arsitektur *Convolutional Neural Network* mendapatkan hasil akurasi sebesar 91,41% pada *optimizer* RMSProp, 92,93% pada *optimizer* Adam, 81,56% pada *optimizer* SGD, dan 68,65% pada *optimizer* AdaDelta.

Kata kunci — *Citra Mata Katarak; Deep Learning; Convolutional Neural Network; Optimizer.*

I. PENDAHULUAN

Katarak merupakan suatu penurunan fungsi progresif kejernihan pada lensa mata. Katarak menjadi salah satu kondisi yang mempengaruhi faktor tertentu seperti usia, aktivitas, dan juga bagi setiap orang yang memiliki penyakit turunan yang menjadi indikasi atau kondisi medis seperti diabetes, dehidrasi akut, gangguan atopik, hipertensi, asam urat (lebih dari 10 tahun, jenis kelamin dan Riwayat keluarga katarak, kemudian trauma mata dan lainnya. [1]

Katarak merupakan salah satu penyebab dalam kasus kebutaan dengan presentase sedikitnya 50% di seluruh dunia menurut *World Health Organization* (WHO, 2013), memperkirakan bahwa penyebab gangguan penglihatan diseluruh dunia adalah gangguan refraksi yang tidak terkoreksi [2]. Katarak merupakan penyebab utama kebutaan di Indonesia, pada hasil survey kebutaan di 15 provinsi pada tahun 2014-2016 menunjukkan 70% hingga 80% penyebab utama kebutaan dan gangguan penglihatan di Indonesia adalah katarak.

Dalam proses menyembuhkan penyakit kebutaan katarak adalah dengan cara pergi ke dokter dan melakukan suatu operasi. Pada dasarnya, hal tersebut dapat diketahui atau diidentifikasi jenisnya dengan dilihat dari gejala-gejala yang diderita pasien. Berdasarkan data dari Perhimpunan Dokter Spesialis Mata Indonesia, jumlah dokter spesialis mata berjumlah kurang lebih 3000 dokter. Hal tersebut tidak sebanding dengan jumlah penderita penyakit mata katarak di Indonesia.

Dalam berkembangnya zaman, tentunya teknologi informasi pengolahan citra merupakan salah satu yang menjadi solusi dalam memenuhi suatu kebutuhan. Dalam klasifikasi Neural Network yang menjadi metode dalam Deep Learning, satu set unit input dan output akan memenuhi koneksi dalam memiliki nilai bobot dalam setiap proses.

Oleh karena itu dibutuhkan suatu sistem kecerdasan buatan dalam proses identifikasi yang dapat membantu menduplikasi kemampuan manusia dalam memahami suatu informasi seperti menentukan seseorang terkena penyakit kebutaan katarak atau tidak melalui informasi citra. Dengan proses ekstraksi ciri digital dapat membantu dalam

mendapatkan karakteristik atau ciri tertentu yang menjadi suatu informasi tertentu dari objek dari suatu citra digital yang membuat suatu citra dapat dibedakan, dikelompokkan dan atau dikenali. Informasi citra digital tersebut menjadi suatu parameter dalam penyakit katarak. Dalam klasifikasi atau identifikasi suatu citra, citra harus diidentifikasi terlebih dahulu ciri pola dari objek tersebut seperti ciri pola bentuk, tekstur dan warna. Dengan begitu suatu pola citra yang telah disegmentasi menjadi beberapa class tertentu dan membentuk suatu pola. Sejauh ini dalam proses klasifikasi atau identifikasi suatu citra yang banyak diaplikasikan menggunakan metode data mining berupa klasifikasi *Neural Network*.

A. Penelitian Terkait

- 1) Penelitian oleh Worung, dkk, pada tahun 2020 mengenai Implementasi *K-Means* dan *K-NN* pada Pengklasifikasian Citra Bunga. Penelitian ini bertujuan untuk melakukan proses metode *K-Means* dan *K-NN* untuk melakukan *Clustering* dan klasifikasi pada dataset bunga lokal Kota Tomohon, Sulawesi Utara. Dari pengujian yang didapatkan mendapatkan akurasi tertinggi dengan hasil 85%. [3]
- 2) Penelitian oleh Bath, Mosalagi, Bhalerao, Katkar, dan Pitale pada tahun 2020 mengenai *Cataract Eye Prediction Using Machine Learning*, penelitian ini bertujuan untuk melakukan proses klasifikasi pada citra mata katarak dan normal dengan menggunakan metode *Convolutional Neural Network*. [4]
- 3) Penelitian oleh Felix, Butarbutar, dan Sirait pada tahun 2019 mengenai Implementasi *CNN* dan *SVM* untuk Identifikasi Penyakit Tomat via Daun. Penelitian ini bertujuan untuk identifikasi citra digital menggunakan supervised classification mendapatkan informasi berupa solusi penanganan dalam mencegah atau menentukan penyakit yang menyerang pada tomat. Hasil pengujian menunjukkan presentase dengan rata-rata akurasi 97.5% pada metode *Convolutional Neural Network* dan hasil presentase rata-rata akurasi 95% pada *SVM*. [5]
- 4) Penelitian oleh Domański, Domańska, Marek, dan Szygula pada tahun 2020 mengenai *Long-Range Dependent Traffic Classification with Convolutional Neural Networks Based on Hurst Exponent Analysis*. Penelitian bertujuan dalam proses klasifikasi untuk mengkaji kemampuan neural Networks pada data lalu lintas internet, hasil yang didapatkan dari proses klasifikasi yaitu akurasi mencapai dengan kisaran antara 83.31% dan 96.94% pada *Fractional Gaussian Noise (FGN)* dan 79.23% dan 89.65% pada *Artificial Neural Network*. [6]
- 5) Penelitian oleh Zulfikar dan Lukman pada tahun 2016 mengenai Perbandingan *Naïve Bayes Classifier* dengan *Nearest Neighbor* untuk Identifikasi Penyakit Mata. Penelitian ini bertujuan dalam proses klasifikasi menggunakan *Naïve Bayes* dan *Nearest Neighbor*, kedua metode ini dikombinasikan dan dibandingkan untuk mendapatkan hasil terbaik. [7]

B. Data Mining

Data Mining merupakan analisa dari peninjauan kumpulan data untuk menemukan hubungan yang tidak diduga dan meringkas data dengan cara yang berbeda dengan sebelumnya, yang bermanfaat bagi pemilik data. *Data mining* terbagi menjadi enam fungsi, diantaranya adalah fungsi deskripsi, fungsi klasifikasi, fungsi prediksi, fungsi estimasi, fungsi pengklasteran, dan fungsi asosiasi. *Data mining* bukanlah bidang ilmu yang berdiri sendiri tetapi terbentuk dan berkaitan dengan bidang ilmu yang lain seperti *database*, *statistic*, pencarian informasi, dan *Artificial Intelligent*. [8]

C. Machine Learning

Machine Learning adalah sub-cabang dari kecerdasan buatan *Artificial Intelligence* yang berfokus pada aspek pembelajaran komputer. *Machine Learning* terbagi menjadi tiga kelas yaitu, *Supervised Learning*, *Unsupervised Learning*, dan *Reinforcement Learning*. [9]

1) Supervised Learning

Tujuan utama dalam *Supervised Learning* adalah proses dalam mempelajari model dari data pelatihan yang berlabel sehingga memungkinkan dalam membuat prediksi dari data yang invisible dan hasil di masa mendatang. Hasil yang akan disimpan mengacu pada sekumpulan data sampel yang memiliki hasil keluaran yang diinginkan sesuai dengan label yang telah diketahui.

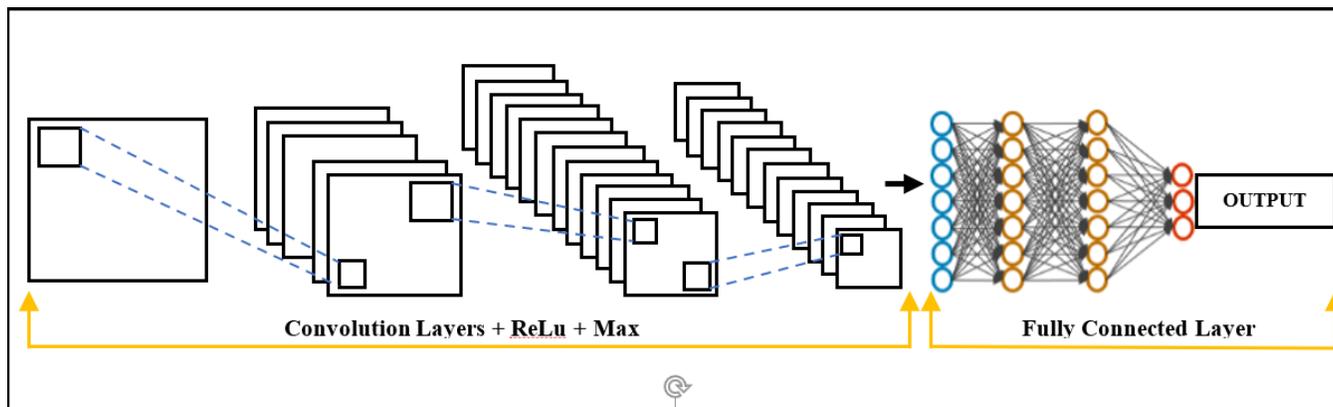
Pada *Supervised Learning* memiliki salah satu metode pembelajaran yaitu *Neural Network* yang dimana pembelajaran ini terbuat dari neuron sederhana yang dibentuk dan disusun dalam beberapa lapisan dan dihubungkan dengan menggunakan suatu nilai. Hal tersebut mensimulasikan cara kerja biologis dari neuron.

Implementasi *Supervised Learning* berupa pemfilteran spam pada *e-mail*. Hal ini terlihat dalam melatih model dengan menggunakan *Machine Learning*, algoritma pada korpus *e-mail* yang telah diberikan label, *e-mail* yang ditandai dengan benar sebagai spam atau tidak dimana proses dalam memprediksi apakah suatu *e-mail* baru termasuk dalam salah satu dari kedua kategori tersebut. [9]

2) Unsupervised Learning

Dalam *Supervised Learning*, dapat dilihat bahwa proses yang diketahui adalah mempelajari model dari data pelatihan yang berlabel sehingga memungkinkan dalam membuat prediksi dari data. Dalam *Unsupervised Learning*, proses yang terjadi yaitu data yang tidak berlabel atau data yang telah diketahui dengan menggunakan Teknik *Unsupervised Learning* dapat melihat proses dalam menjelajahi struktur data untuk mengekstrak informasi yang berarti tanpa panduan variable hasil atau fungsi dari hasil yang telah diketahui. [9]

Pada *Unsupervised Learning*, *Neural Networks* mengatur jaringannya sendiri dalam teknik pembelajaran yang mengatur neuron dengan cara meminimalkan fungsi error yang dirancang untuk suatu masalah.



Gambar 1. Arsitektur CNN

3) Reinforcement Learning

Reinforcement Learning merupakan bagian dari *Machine Learning* yang memiliki tujuan dalam mengembangkan sistem (*agent*) untuk meningkatkan kinerja berdasarkan interaksi dengan environment yang ada. Berdasarkan informasi tentang keadaan lingkungan saat ini biasanya mencakup apa yang disebut reward signal. Pembelajaran ini memiliki umpan balik tidak mengoreksi label atau nilai kebenaran dasar tetapi mengukur seberapa baiknya Tindakan tersebut dalam mengukur suatu reward function. Melalui interaksi dengan lingkungan, seorang agent dapat melakukan pendekatan *trial-and-error* pembelajaran penguatan atau *deliberative planning*.

Contoh populer dari *Reinforcement Learning* adalah mesin aplikasi catur. Agent memutuskan serangkaian Gerakan tergantung pada keadaan papan atau *environment* yang ada sebagai *reward planning*-nya yaitu menang atau kalah di akhir permainan. [9]

D. Deep Learning

Deep Learning merupakan suatu subset khusus dari *Machine Learning* yang berdasarkan pada penggunaan Neural Network dalam meniru perilaku aktivitas otak. Pembelajaran ini disebut sebagai deep karena dalam proses pemodelan dan data yang dimanipulasi oleh sejumlah lapisan tersembunyi. Dalam jenis pemodelan ini informasi yang spesifik akan dikumpulkan dari setiap lapisan. Misalnya, pada satu lapisan tertentu menemukan tepi gambar sementara lapisan lainnya menemukan rona pada citra yang diidentifikasi [10]. Salah satu metode *deep learning* yang sedang berkembang yaitu *Convolutional Neural Network*.

E. Convolutional Neural Network

Convolutional Neural Network (CNN) adalah salah satu jenis neural network yang biasa digunakan pada data gambar yang digunakan untuk mendeteksi dan mengenali objek. *Convolutional Neural Network* (CNN) dirancang untuk melakukan pekerjaan dalam memproses data ke dalam bentuk array, misalnya gambar berwarna yang terdiri dari tiga 2D array yang memiliki intensitas piksel di tiga saluran warna, *Convolutional Neural Network* memanfaatkan sifat *nature signals* yaitu koneksi lokal, *share weights*, *pooling*, dan penggunaan banyak lapisan.

Terdapat empat model dalam proses pengolahan citra, yaitu *Convolution Layer*, *Pooling Layer*, *Dropout Layer*, *Fully Connected Layer* [11]. Dengan empat bagian ini citra yang akan diproses akan dilakukan filter, citra akan direduksi dimana bagian ini akan mengambil nilai terbesar dari setiap grid dan kemudian mengurangi dimensi data, kemudian dilakukan pencegahan over-fitting dan setelah itu ditransformasi pada dimensi data agar dapat diklasifikasikan. Setiap model ini harus memiliki data pelatihan yang baik agar proses dalam klasifikasi dapat mendapatkan hasil yang akurat. Pada gambar 1 merupakan gambaran dari bentuk *convolutional neural network*.

1) Convolutional Layer

Pada lapisan konvolusi ini menggunakan filter untuk mendeteksi karakter dari suatu objek atau citra yang menghasilkan hasil linear dari citra input yang sesuai. Dalam proses ini terdapat parameter untuk memodifikasi setiap lapisan diantaranya ada *filter*, *stride*, dan *padding*. Pada *stride* berguna untuk mengontrol bagaimana proses filter pada data input dimana setiap pergerakan di sepanjang ukuran piksel yang telah ditentukan. Pada parameter *padding* terdapat penambahan ukuran piksel dengan nilai tertentu disekitar data yang diinput agar hasil yang didapatkan tidak terlalu kecil sehingga tidak banyak informasi yang akan hilang. [12]

2) ReLu Layer

ReLU (*Rectification Linear Unit*) adalah lapisan yang berguna untuk mengenalkan nonlinearitas ke jaringan serta meningkatkan representasi dari suatu model dimana output yang dihasilkan berupa peta fitur yang telah diperbaiki. [12]

3) Pooling

Lapisan Pooling merupakan lapisan dalam mengambil data untuk mengurangi dimensi pada fitur. Fitur yang telah diperbaiki akan melewati lapisan penggabungan untuk menghasilkan fitur yang telah digabungkan. [12]

4) Fully Connected Layer

Pada lapisan ini terhubung secara penuh pada setiap neurons yang memiliki koneksi penuh pada setiap aktivasi yang telah dilakukan pada lapisan sebelumnya. [12]

F. Optimizer

Parameter *Convolutional Neural Network* yang dilatih memiliki peran utama dalam mengembangkan pelatihan model secara efisien dan efektif dalam menghasilkan hasil yang akurat. Strategi pada optimisasi memiliki pengaruh besar pada proses pembelajaran model dan proses prediksi, hal ini kemudian membantu serta menyesuaikan parameter internal model. [13]

1. Momentum merupakan teknik untuk mempercepat *Stochastic Gradient Descent* (SGD) dengan mengubah sebagian momentum ke arah yang akan diproses dan minimal ke arah yang berfluktuasi. Pada saat tujuan mencapai minimum lokal, momentumnya akan sangat tinggi. Oleh karena itu, model yang akan masuk ke minimum lokal dapat diabaikan. Metode ini sering melakukan pembaruan besar yang dimana model dapat mungkin berpengaruh kehilangan nilai minimum yang sebenarnya. [13]
2. RMSprop merupakan *optimizer* yang memanfaatkan besarnya gradien terbaru untuk menormalkan gradien. Pada metode ini, akan dilakukan peningkatan parameter dan akan menurunkannya dengan gradien, hal tersebut memiliki tingkat pembelajaran yang dapat melakukan penyesuaian. [13]
3. *Adaptive Moment Estimation* (Adam) merupakan metode dalam menentukan tingkat pembelajaran untuk setiap parameter. Skala pembelajaran untuk setiap parameter diperoleh berdasarkan pada kepentingan yang diperlukan. Metode ini menyimpan nilai rata-rata eksponensial pada gradien sebelumnya. [13]
4. Adadelta merupakan *optimizer* yang menggunakan besaran gradien dan langkah terbaru dalam mendapatkan kecepatan pembelajaran adaptif. Metode ini menyimpan rata-rata eksponensial di atas gradien dan *learning rate* yang memiliki skala untuk setiap parameter individu yang diperoleh dari rasio. [13]

G. Pengolahan Citra Digital

Mata merupakan indra terbaik pada manusia sehingga citra atau gambar memiliki peran penting dalam perspektif manusia. Namun demikian indra mata memiliki keterbatasan dalam menangkap sinyal elektromagnetik. Pada komputer atau mesin pencitraan yang ada dapat menangkap sinyal hampir keseluruhan elektromagnetik. Dalam pengolahan citra digital telah memberikan kemajuan yang luar biasa pada bidang kedokteran, industri, pertanian, geologi, kelautan, dan lainnya. Pengolahan citra digital meliputi *image processing*, *image analysis*, *image understanding*, dan *computer vision*. [14]

Pada *image processing* mempunyai masukan dan keluaran berupa citra, contohnya citra ditransformasikan ke dalam bentuk citra lainnya. Pada *image analysis*, masukan citra dengan keluaran bukan citra melainkan berupa hasil dari pengukuran atau analisa dari pada citra tersebut, contohnya, citra wajah dianalisis untuk mendapatkan fitur wajah. Pada *image understanding* memiliki masukan berupa citra dan hasil keluaran bukan citra tetapi memiliki deskripsi tingkat tinggi dari citra tersebut, contohnya, suatu input citra seseorang dengan keluaran deskripsi dari orang

tersebut seperti ekspresi dari wajah seseorang tersebut. Pada *computer vision* dilakukan komputerisasi penglihatan pada manusia atau membuat citra digital dari citra sebenarnya. [15]

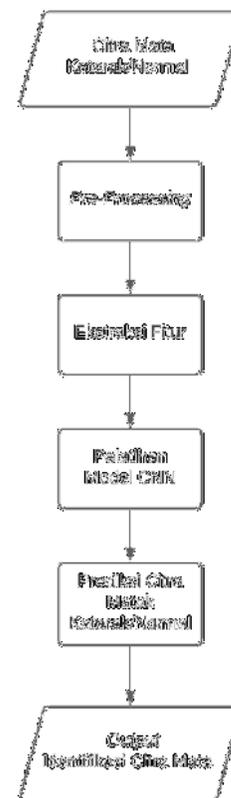
Citra digital adalah image dimana $f(x,y)$ yang telah dibentuk menjadi diskrit baik koordinat spasialnya atau tingkat identitasnya. Citra yang didapatkan didigitalisasikan atau dibentuk menjadi diskrit agar mudah diolah dan disimpan dalam media penyimpanan.

Pengolahan citra atau *image processing* bertujuan untuk memperbaiki kualitas citra, dimana proses yang akan dilakukan seperti menginput citra dan hasilnya juga berupa citra kemudian mengekstraksi fitur untuk mendapatkan kualitas citra yang akan digunakan dalam ekstraksi ciri tekstur dan setelah itu pengelompokan data citra pola tekstur dimana berdasarkan nilai contrast dan energy ke dalam satu kelompok untuk memperbaiki kualitas citra. Langkah-langkah tersebut dapat membantu mempermudah proses oleh komputer. Pada perkembangan dunia komputasi dengan meningkatnya kapasitas dan kecepatan proses komputer membuat pengolahan citra dalam mentransformasi citra yang pada asalnya kurang baik menjadi citra keluaran yang lebih baik dan berkualitas.

II. METODE

A. Prinsip Kerja Sistem

Dalam Gambar 2 merupakan diagram prinsip kerja sistem untuk memperlihatkan garis besar alur proses kerja dalam sistem.



Gambar 2. Diagram Prinsip Kerja Sistem

TABEL I
 JUMLAH GAMBAR *DATASET*

	<i>TRAINING</i>	<i>Test</i>
Katarak	100 gambar	30 gambar
Normal	100 gambar	30 gambar
Total	200 gambar	60 gambar

Pada gambar 2 merupakan diagram prinsip kerja sistem dirancang untuk menganalisa setiap tahapan yang akan digunakan dalam proses mengidentifikasi citra penyakit mata katarak dalam menggunakan arsitektur *Convolutional Neural Network*. Dalam perancangan sistem ini akan dijelaskan setiap proses tahapan yang akan dilakukan sehingga sistem dapat melakukan identifikasi menggunakan arsitektur convolutional neural network.

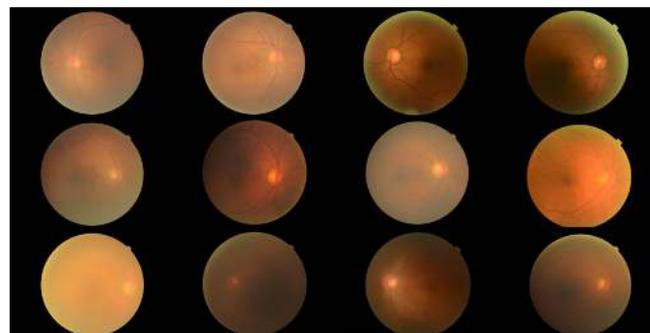
Pada tahap pertama pengguna memasukan berkas citra mata katarak atau mata normal yang akan menjadi masukan dalam sistem untuk melakukan proses identifikasi. Dalam proses *pre-processing*, gambar yang telah masuk akan melakukan *rescale* yang dapat dengan mudah dalam membantu sistem untuk melakukan pekerjaannya berikutnya yaitu dalam melakukan pengenalan dalam ekstraksi ciri fitur, hal ini dilakukan untuk pengambilan suatu ciri objek atau pola yang menggambarkan karakteristik dari objek gambar mata. Dalam proses berikutnya, yaitu tahapan dalam melatih gambar yang akan diolah, dilakukan proses pelatihan menggunakan arsitektur *convolutional neural network*, yang terdiri dari beberapa lapisan yaitu lapisan masukan, lapisan tersembunyi, dan lapisan keluaran. Model yang dibangun tersebut kemudian disimpan yang berguna ketika dalam menjalankan proses berikutnya. Setelah melewati proses pelatihan, data gambar katarak maupun normal akan menjadi sebuah angka yang kemudian dilanjutkan dalam proses klasifikasi atau prediksi. Klasifikasi atau prediksi tersebut mengeluarkan hasil berupa mata katarak maupun normal yang sudah terlabeli.

B. Data yang digunakan

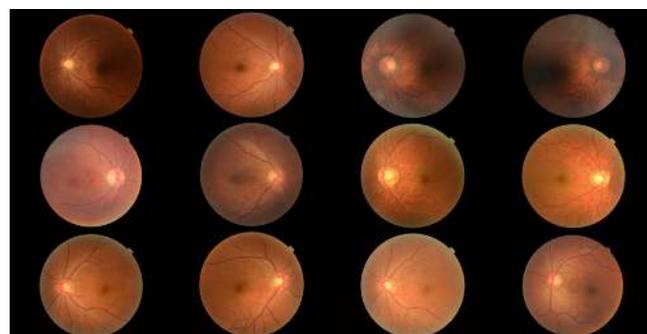
Data yang digunakan dalam penelitian ini yaitu data gambar fundus mata katarak dan gambar fundus mata normal yang di ambil di *Kaggle*. Data-data tersebut kemudian dilakukan proses label secara manual kedalam kelas folder *training*, dan folder *test*, hal ini dilakukan dalam memudahkan proses perancangan sistem identifikasi yang akan diolah ke dalam proses pelatihan dan proses prediksi.

Pada penelitian ini menggunakan data gambar fundus mata katarak sebanyak 130 dan gambar fundus mata normal sebanyak 130 yang dimana 200 gambar fundus mata katarak dan gambar fundus mata normal pada masing-masing kategori untuk folder *training* dan 60 gambar fundus mata katarak dan fundus mata normal kedalam folder *test* pada setiap masing-masing kategori.

Pada gambar 3 merupakan contoh dan bentuk dari data citra fundus mata katarak, sedangkan untuk data citra fundus mata normal dapat dilihat pada gambar 4.



Gambar 3. Data Citra Fundus Mata Katarak



Gambar 3. Data Citra Fundus Mata Normal

C. Evaluasi Sistem

Dalam penelitian ini dilakukan evaluasi yang dimana evaluasi merupakan suatu kegiatan untuk memeriksa kinerja dari sistem yang dibangun atau metode yang dikembangkan dalam penelitian ini untuk mendapatkan hasil akhir yang sesuai.

Pada proses evaluasi dalam penelitian ini akan dilakukan pengujian terhadap metode dari arsitektur *Convolutional Neural Network*, yang dimana pengujian dilakukan pada nilai parameter pertama (*KI*) pada lapisan konvolusi dan pada *optimizer* yang akan digunakan. Pada proses evaluasi juga dilakukan pada aplikasi yang telah dibangun, hal ini dilakukan untuk dapat mengetahui seberapa akurat sistem yang telah dibangun.

III. HASIL DAN PEMBAHASAN

A. Pembentukan dan Pemilihan Model

Pada pembentukan model dan pemilihan model merupakan tahapan yang dilakukan untuk menentukan model yang akan dipilih sesuai dengan hasil pengujian. Sebelum melakukan proses klasifikasi atau prediksi tentunya diperlukan model yang mendukung dalam proses tersebut, yang kemudian model tersebut yang akan melaksanakan proses pelatihan yang berfungsi untuk menjadi bahan pembelajaran bagi model yang akan digunakan sehingga mendapatkan hasil prediksi dengan baik yang dibangun menggunakan arsitektur convolutional neural network.

Pada pembentukan dan pemilihan model ini menggunakan 220 data gambar mata katarak dan mata normal yang dilabel secara manual. Data gambar tersebut terbagi menjadi 200 data *training* dan 20 data *validation*.

TABEL II
Parameter Arsitektur

Lapisan	Ukuran Piksel	Node		
		Evaluasi 1	Evaluasi 2	Evaluasi 3
Input	255 x 255 x 3			
Conv1	3 x 3 x 3	16	32	64
Max Pool1	2 x 2			
Conv2	3 x 3	32	64	128
Max Pool2	2 x 2			
Conv3	3 x 3	64	128	256
Max Pool3	2 x 2			
TC1		128	128	128
TC2		1	1	1
Output	255 x 255 x 3			

TABEL III
PENGUJIAN OPTIMIZER RMSPROP

	Data	Training
	Accuracy	Loss
Evaluasi 1	91.41%	0.1979
Evaluasi 2	81.44%	0.2425
Evaluasi 3	83.36%	0.3344

Dalam arsitektur CNN akan dilakukan pengujian terhadap parameter dan pemilihan *optimizer*, nilai *filter* pada lapisan konvolusi, penggunaan lapisan konvolusional dan nilai *dropout* untuk mengetahui performa terbaik dari setiap parameter dan *optimizer* yang akan dipilih.

Pada tabel II merupakan bentuk model yang akan digunakan pada setiap pengujian dan pelatihan termasuk menampilkan pemilihan nilai parameter pertama pada lapisan konvolusi untuk menjadi evaluasi bersamaan dengan pengujian *optimizer* yang akan dibuat.

1) Pengujian Optimizer

Pada pengujian pertama dilakukan dengan pemilihan parameter terhadap nilai filter lapisan konvolusi yang telah dibahas sebelumnya sebanyak 16, 32, 64, 128, dan 256 pada masing-masing lapisan konvolusi, dan dilakukan bersamaan dengan pemilihan beberapa *optimizer* yang akan digunakan seperti RMSprop, ADAM, SGD, dan AdaDelta pada proses pelatihan yang telah berlangsung.

Pada tabel III merupakan hasil dari proses evaluasi terhadap arsitektur yang telah dibangun, dengan memperhatikan nilai filter parameter pertama pada lapisan konvolusi yang digunakan pada evaluasi 1 sebanyak 16, 32, dan 64, evaluasi 2 sebanyak 32, 64, dan 128, dan evaluasi 64, 128, dan 256 pada setiap masing-masing lapisan konvolusi. Pada evaluasi yang berlangsung pada menggunakan *optimizer* RMSprop. Hasil dengan performa terbaik didapatkan pada evaluasi pertama dengan nilai akurasi data *training* sebesar 91.41%.

TABEL IV
PENGUJIAN OPTIMIZER ADAM

	Data	Training
	Accuracy	Loss
Evaluasi 1	92.93%	0.1850
Evaluasi 2	76.98%	0.2425
Evaluasi 3	83.36%	0.3344

TABEL V
PENGUJIAN OPTIMIZER SGD

	Data	Training
	Accuracy	Loss
Evaluasi 1	72.43%	0.5187
Evaluasi 2	81.56%	0.4547
Evaluasi 3	70.93%	0.5879

TABEL VI
PENGUJIAN OPTIMIZER ADADelta

	Data	Training
	Accuracy	Loss
Evaluasi 1	52.19%	0.6893
Evaluasi 2	59.09%	0.6812
Evaluasi 3	68.65%	0.6634

Kemudian pada tabel IV merupakan hasil dari proses pemilihan model dalam evaluasi terhadap arsitektur yang telah dibangun menggunakan *optimizer Adaptive Moment Estimation* (Adam), dengan nilai filter parameter pertama pada lapisan konvolusi yang digunakan pada evaluasi 1 sebanyak 16, 32, dan 64, evaluasi 2 sebanyak 32, 64, dan 128, dan evaluasi 64, 128, dan 256 pada masing-masing lapisan konvolusi. Hasil dengan performa terbaik didapatkan pada evaluasi pertama dengan nilai akurasi data *training* sebesar 92.93%.

Dilanjutkan evaluasi pemilihan model dengan menggunakan *optimizer Stochastic Gradient Descent* (SGD). Pembentukan model mendapatkan hasil dari proses evaluasi terhadap arsitektur yang telah dibangun, dengan nilai filter parameter pertama pada lapisan konvolusi yang digunakan pada evaluasi 1 sebanyak 16, 32, dan 64, evaluasi 2 sebanyak 32, 64, dan 128, dan evaluasi 64, 128, dan 256 pada masing-masing lapisan konvolusi. Hasil dengan performa terbaik didapatkan pada evaluasi kedua dengan nilai akurasi data *training* sebesar 81.56%.

Pada pemilihan model terhadap penggunaan *optimizer Adadelta* mendapatkan hasil dari proses evaluasi terhadap arsitektur yang telah dibangun, dengan nilai filter parameter pertama pada lapisan konvolusi yang digunakan pada evaluasi 1 sebanyak 16, 32, dan 64, evaluasi 2 sebanyak 32, 64, dan 128, dan evaluasi 64, 128, dan 256 pada masing-masing lapisan konvolusi. Hasil dengan performa terbaik didapatkan pada evaluasi kedua dengan nilai akurasi data *training* sebesar 68.65%.

TABEL VII
PENGUJIAN LAPISAN KONVOLUSI

	Data Training	
	Accuracy	Loss
3 Konvolusi	92.93%	0.1850
4 Konvolusi	91.21%	0.2567
5 Konvolusi	90.45%	0.2085

TABEL VIII
PENGUJIAN NILAI DROPOUT

		Data Training	
D1	D2	Accuracy	Loss
0.25	0.5	93.31%	0.2020
0.26	0.6	82.55%	0.3594
0.27	0.7	78.54%	0.5590
0.28	0.8	80%	0.6146
0.29	0.9	61.87%	0.6520

2) Pengujian Lapisan Konvolusi

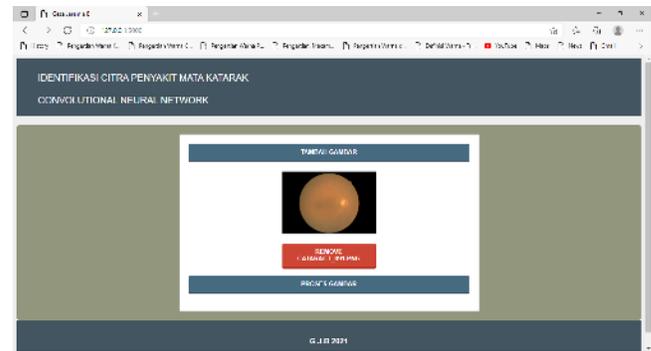
Setelah mendapatkan model terbaik pada pengujian sebelumnya dimana proses pengujian tersebut untuk mendapatkan model terbaik pada beberapa pemilihan nilai parameter pertama pada lapisan konvolusi sekaligus pengujian terhadap *optimizer* yang akan digunakan. dipilihnya model dengan nilai parameter pertama sebanyak 16, 32, dan 64, serta *optimizer* Adam untuk ke tahap pengujian berikutnya. Dengan menggunakan hasil pengujian terbaik sebelumnya. Pemilihan model dalam proses pengujian terhadap beberapa lapisan konvolusi didapatkan hasil performa terbaik yang didapatkan yaitu dengan menggunakan 3 lapisan konvolusi pada model mendapatkan nilai akurasi sebesar 92.93% pada data *training*. Hasil yang didapatkan dapat dilihat pada tabel VII.

3) Pengujian Nilai Dropout

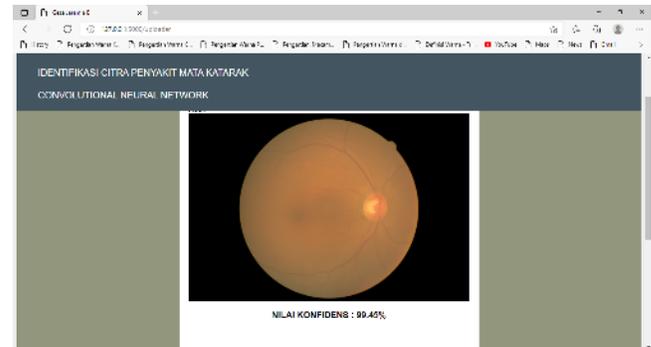
Pemilihan model yang telah didapatkan sebelumnya kemudian dilanjutkan ke tahap pengujian berikutnya, model terbaik diaplikasikan kembali dan menguji nilai dropout untuk mengetahui performa terbaik berdasarkan nilai *dropout*. Pada tiga lapisan konvolusi yang menjadi evaluasi nilai parameter terbaik berdasarkan hasil yang didapatkan dengan nilai dropout pertama dan kedua sebagai berikut 0.25 dan 0.5, 0.26 dan 0.6, 0.27 dan 0.7, 0.28 dan 0.8, serta 0.29 dan 0.9. Berdasarkan pengujian nilai dropout tersebut dapat dilihat pada tabel VIII bahwa penggunaan nilai *dropout* sebanyak 0.25 dan 0.5 mendapatkan hasil akurasi sebesar 93.31% pada data *training*.

B. Implementasi Antarmuka Sistem

Pada proses implementasi antarmuka sistem merupakan proses perancangan dan pembuatan aplikasi web menggunakan *framework* dan HTML.



Gambar 4. Tampilan Halaman Awal



Gambar 5. Tampilan Halaman Hasil

Tampilan antarmuka sistem merupakan tampilan pada aplikasi atau tampilan visual dari suatu sistem yang membuat pengguna dapat melakukan interaksi dengan sistem yang telah dibangun dengan mudah. Pada Gambar 4 merupakan halaman *home* atau halaman awal pada sistem yang dibangun. Tampilan halaman awal menunjukkan citra gambar mata yang dimasukkan pada sistem untuk melakukan tahap selanjutnya pada tombol proses gambar atau menghapus gambar ketika pengguna ingin mengganti citra mata sesuai yang diinginkan dan gambar 5 merupakan tampilan halaman hasil pada sistem.

C. Evaluasi Sistem

Setelah melakukan proses pembentukan dan pemilihan model yang dimana terdapat parameter, *optimizer*, serta penggunaan lapisan konvolusi sehingga mendapatkan model dengan performa terbaik, kemudian dilanjutkan ke tahap proses evaluasi sistem untuk menguji model terbaik pada arsitektur *convolutional neural network*.

Model terbaik yang telah dibentuk kemudian dilakukan evaluasi dan prediksi, pada proses tahapan evaluasi dan prediksi ini menggunakan dua model dengan performa terbaik dan menggunakan data *testing* untuk mengetahui keakuratannya. Pada hasil prediksi model akan terbentuk kedalam dua kelas, yaitu mata katarak dan mata normal. Prediksi yang telah dibuat. Kelas yang telah diprediksi kemudian akan dihitung total hasil prediksi dari jumlah kelas dan dibandingkan dengan menggunakan *Confusion Matrix* seperti pada tabel XI dan tabel X.

TABEL IX
CONFUSION MATRIX PADA PARAMETER TERBAIK PERTAMA

Aktual	Data Test	
	Cataract	Normal
Cataract	25	5
Normal	2	29

TABEL X
CONFUSION MATRIX PADA PARAMETER TERBAIK KEDUA

Aktual	Data Test	
	Cataract	Normal
Cataract	28	2
Normal	7	23

TABEL XI
PERFORMANSI MODEL

Dropout		Performansi		
1	2	Accuracy	Precision	Recall
0.26	0.5	95%	83.33%	96.15%
0.26	0.6	90%	93.33%	80%

Hasil dari evaluasi sistem yang telah dilakukan terhadap dua model sistem yaitu mendapatkan nilai akurasi 95% dengan menggunakan nilai dropout 0.25 dan 0.5 serta nilai dropout 0.26 dan 0.6 mendapatkan nilai akurasi 90%, sehingga dapat diketahui kedua model tersebut melakukan klasifikasi atau prediksi dengan tingkat keakuratan yang cukup baik. Nilai precision pada penggunaan dropout 0.25 dan 0.5 sebesar 83.33% serta nilai dropout 0.26 dan 0.6 mendapatkan nilai precision 93.33% kemudian performansi recall pada penggunaan dropout 0.25 dan 0.5 sebesar 96.15% serta nilai dropout 0.26 dan 0.6 mendapatkan nilai recall 80%, yang berarti kedua model tersebut melakukan prediksi dengan benar hampir pada keseluruhan data pada kelas mata cataract dan mata normal.

IV. KESIMPULAN DAN SARAN

A. Kesimpulan

Berdasarkan hasil dari penelitian dan pengujian pada sistem yang telah dibangun, maka diambil kesimpulan pada penelitian yaitu implementasi dari analisa *Convolutional Neural Network* mendapatkan hasil terbaik pada pengujian nilai parameter pertama dengan 3 lapisan konvolusi menggunakan *optimizer* Adam dan nilai *dropout* sebanyak 0.25 dan 5 serta 0.26 dan 6 dengan nilai akurasi yang didapatkan yaitu 93.31% pada data *training* dan 95% pada data *test* serta 82.55% pada data *training* dan 90% pada data *test*.

B. Saran

Berdasarkan kesimpulan diatas, beberapa saran penelitian untuk mengembangkan penelitian yang telah dilakukan, antara lain, perlu mengembangkan rancangan pada arsitektur *Convolutional Neural Network* agar sistem dapat lebih baik lagi dalam belajar. Sistem yang telah dibangun baru bisa dilakukan pelatihan terhadap citra mata normal dan citra mata katarak, sehingga masih dimungkinkan dilakukan penelitian identifikasi citra dengan data set yang dalam penelitian yang berkaitan dengan metode arsitektur *Convolutional Neural Network* serta dengan nilai parameter

dan optimizer atau arsitektur lainnya yang mungkin untuk mendapatkan hasil yang lebih baik. Penelitian berikutnya dapat menggunakan komputer dengan spesifikasi RAM yang tinggi untuk mendapatkan hasil komputasi yang lebih cepat.

V. KUTIPAN

- [1] M. Hamidi and A. Royadi, "Faktor-Faktor Yang Berhubungan Dengan Terjadinya Katarak Senilis Pada Pasien Di Poli Mata Rsd Bangkinang," *J. Ners Univ. Pahlawan Tuanku Tambusai*, vol. 1, no. 1, pp. 125–138, 2017.
- [2] A. N. Aini and Y. D. P. Santik, "Kejadian Katarak Senilis di RSUD Tugurejo," *HIGEIA (Journal Public Heal. Res. Dev.)*, vol. 2, no. 2, pp. 295–306, 2018, doi: 10.15294/higeia.v2i2.20639.
- [3] D. T. Worung, S. Sompie, and ..., "Implementasi K-Means dan K-NN pada Pengklasifikasian Citra Bunga," *J. Tek. ...*, vol. 15, no. 3, pp. 217–222, 2020, [Online]. Available: <https://ejournal.unsrat.ac.id/index.php/informatika/article/view/31965>.
- [4] S. Bhat, S. Mosalagi, T. Bhalerao, P. Katkar, and R. Pitale, "Cataract Eye Prediction using Machine Learning," *Int. J. Comput. Appl.*, vol. 176, no. 35, pp. 46–48, 2020, doi: 10.5120/ijca2020920441.
- [5] Felix, S. Faisal, T. F. M. Butarbutar, and P. Sirait, "Implementasi CNN dan SVM untuk Identifikasi Penyakit Tomat via Daun," *Issn 2622-8130*, vol. 20, no. 2, pp. 117–134, 2019.
- [6] K. Filus, A. Domański, J. Domańska, D. Marek, and J. Szygula, "Long-range dependent traffic classification with convolutional neural networks based on hurst exponent analysis," *Entropy*, vol. 22, no. 10, pp. 1–15, 2020, doi: 10.3390/e22101159.
- [7] W. B. Zulfikar and N. Lukman, "Perbandingan Naive Bayes Classifier Dengan Nearest Neighbor Untuk Identifikasi Penyakit Mata," *J. Online Inform.*, vol. 1, no. 2, pp. 82–86, 2016, doi: 10.15575/join.v1i2.33.
- [8] E. Buulolo, "Data Mining Untuk Perguruan Tinggi." p. 91, 2020.
- [9] S. Mirjalili, *Evolutionary Machine Learning Techniques Algorithms and Applications*. 2019.
- [10] R. Devine and M. Pawlus, *Hands-On Deep Learning with R*. Packt Publishing, 2020.
- [11] E. N. Arrofiqoh and H. Harintaka, "Implementasi Metode Convolutional Neural Network Untuk Klasifikasi Tanaman Pada Citra Resolusi Tinggi," *Geomatika*, vol. 24, no. 2, p. 61, 2018, doi: 10.24895/jig.2018.24-2.810.
- [12] Suyanto, K. N. Ramadhani, and S. Mandala, "Deep Learning Modernisasi Machine Learning untuk Big Data," in *DEEP LEARNING Modernisasi Machine Learning untuk Big Data*, Informatika, 2019, pp. 33–41.
- [13] J. Hemanth and V. E. Balas, *Nature Inspired Optimization Techniques for Image Processing Applications*. Springer Nature Switzerland AG, 2019.
- [14] B. S. Kurniawan, S. R. Sentinuwo, and O. A. Lintang, "Aplikasi Pengenal Citra Nomor Kendaraan Bermotor Menggunakan Metode Template Matching," *J. Tek. Inform.*, vol. 8, no. 1, May 2016, doi: 10.35793/jti.8.1.2016.12199.
- [15] D. Putra, "Pengolahan Citra Digital," no. April, p. 420, 2010.



Geza Jeremia Bu'ulölö, lahir di Manado pada tanggal 28 Juli 2000 Penulis bertempat tinggal di Teling, Tingkulu, Lingkungan II, Manado. Penulis menyelesaikan Pendidikan di SD GMIM 17 Manado (2006-2011), kemudian di SMP N 1 Manado dan lulus pada tahun 2014, dan di SMA Kr. Eben Haezar Manado pada tahun (2014-2017). Penulis kemudian melanjutkan pendidikan di Universitas Sam Ratulangi dengan mengambil Program Studi Teknik Informatika Jurusan Teknik Elektro Fakultas Teknik, Manado, Sulawesi Utara.