

Klasifikasi Iris Biometrik menggunakan Convolutional Neural Network (CNN) dengan Metode Segmentasi Bitplane Slicing

Iqbal Hapid Sukana Putra¹, Said Al Faraby², Untari Novia Wisesty³

^{1,2,3}Fakultas Informatika, Universitas Telkom, Bandung

¹iqbalhapid18@gmail.com, ²said.al.faraby@gmail.com, ³untarinw@telkomuniversity.ac.id,

Abstrak

Iris merupakan bagian dari mata yang memberikan tekstur dan warna yang unik pada setiap individu. Bagian iris merupakan area gelang yang dibatasi oleh pupil dan *sklera* atau bagian putih dari mata. Karakteristik unik ini dapat dimanfaatkan sebagai basis dalam sistem keamanan biometrik. Namun dalam praktik implementasinya, banyak hal yang menjadi permasalahan dalam proses pembuatan sistem. Permasalahan tersebut antara lain seperti proses penghapusan derau yang kurang praktis atau algoritma pengenalan sistem yang terlalu kaku terhadap perubahan gambar inputan. Oleh karena itu, dibutuhkan sistem yang dibangun berdasarkan permasalahan tersebut sebagai solusi. Sebagai langkah solusi dalam proses membangun sistem, digunakanlah metode segmentasi *Bitplane Slicing* yang bertujuan dalam untuk mencari area iris dengan tahapannya yang lebih praktis. Beberapa pengujian segmentasi menggunakan 50 *class* dari dua *dataset* dan hasil segmentasi terbaik dipilih masing-masing *dataset* sebanyak 25 *class* sebagai *input data* untuk pengujian klasifikasi.

CNN sebagai metode klasifikasi yang berbasis jaringan pembelajaran, diyakini dapat menangani perubahan pada gambar inputan sistem sehingga timbul toleransi pada sistem. Berbeda dengan sistem yang berbasis *template matching*, sistem yang terbentuk tentunya lebih kaku dan peka terhadap perubahan gambar. Berdasarkan sedikitnya informasi tentang CNN yang diaplikasikan ke pengenalan iris, maka dibutuhkan pengujian yang diharapkan dapat menjadi nilai ukur dari sisi akurasi dan efisiensi arsitektur jaringan yang dibentuk. Pengujian dilakukan dengan menggunakan 25 *class* yang merupakan hasil pengujian segmentasi terbaik masing-masing dua *dataset* yaitu *dataset* pegawai bandara dan *dataset* iris CASIA, diperoleh akurasi 82% untuk *dataset* pegawai bandara dan 98,1% untuk *dataset* iris CASIA.

Kata kunci: Iris Biometrik, segmentasi, klasifikasi, Bitplane Slicing, Convolutional Neural Network

Abstract

Iris is a part of the eye that gives a unique texture and color to each individual. The iris is the area of the bracelet which is bounded by the pupils and sclera or the white part of the eye. These unique characteristics can be used as a basis in biometric security systems. But in the practice of its implementation, many problems include like the less practical noise removal process or system recognition algorithms that are too rigid. Therefore, a system is built based on these problems as a solution. As a solution step in the process of building the system, the Bitplane Slicing segmentation method is used which aims to find the iris area with more practical steps. The results of several tests use 50 classes from two datasets and the best segmentation results are selected by each dataset of 25 classes as input data for classification testing. .

CNN as a classification method that is based on learning networks, is believed to be able to handle changes in input system images resulting in tolerance to the system. Unlike the template matching system, the system that is formed is certainly stiffer and sensitive to image changes. Based on the lack of information about CNN applied to iris recognition, testing is needed which is expected to be a measuring value in terms of the accuracy and efficiency of the network architecture formed. Tests carried out using 25 classes which were the results of testing the best segmentation from two datasets consisting of airport employee datasets and CASIA lamp iris datasets, obtained accuracy 82% for airport employee datasets and 98.1% for CASIA lamp iris datasets.

Keywords: Iris Biometric, segmentation, classification, Bitplane Slicing, Convolutional Neural Network

1. Pendahuluan

1.1 Latar Belakang

Sistem identifikasi iris pada dasarnya adalah sistem pengenalan subjek untuk diverifikasi oleh sistem sehingga subjek tersebut dapat dikenali oleh sistem dengan pemrosesan objek iris sebagai inputannya [5]. Terhitung dari banyaknya jumlah penelitian dan metode yang digunakan. Pada umumnya sistem biometrik berbasis citra iris terdiri dari empat tahapan dimulai dari tahap akuisisi citra iris lalu segmentasi atau lokalisasi iris kemudian ekstraksi ciri dan yang terakhir adalah pencocokan [4].

Tahap segmentasi atau lokalisasi merupakan tahapan yang penting karena pada tahapan ini adalah mencari area iris dalam suatu citra. Sehingga jika area iris yang dilokalisasi tidak tepat akan berpengaruh pada hasil yang akan didapatkan. Tingkat akurasi dan performansi proses segmentasi tergantung dari data dan metode yang digunakan. Contoh penelitian segmentasi yang sudah dilakukan Masek menghasilkan akurasi dalam lokalisasi iris sebesar 90.9%, Camus dan Wildes menghasilkan akurasi 99.5% pada citra mata tanpa kaca mata dan 66.6% pada citra mata dengan kaca mata [1]. Sedangkan Bradford Bonney, Robert, Delores dan Yingzi menerapkan metode berbasis *bitplane* pada tahap segmentasi terbukti lebih praktis dan mudah dalam ekstraksi lingkaran pupil hanya dengan beberapa tahapan dekomposisi [6].

Kemudian untuk metode klasifikasi, penggunaan metode klasifikasi berbasis *machine learning* khususnya *neural network* cukup akurat dan berpotensi besar dalam segi mengolah data yang sangat banyak [2]. Salah satu penelitian pengolahan citra berbasis *neural network* dengan metode khusus Convolutional Neural Network (CNN) oleh Orave, Milos terbukti akurat dalam mengidentifikasi pengenalan wajah [13]. Namun, penelitian tentang penggunaan CNN sebagai metode klasifikasi terbilang sedikit. Informasi mengenai aplikasi CNN dalam masalah klasifikasi biometrik seringkali tidak menjelaskan secara detail bentuk pengaplikasiannya dan arsitektur yang digunakan serta tingkat akurasi yang didapatkan [14].

1.2 Perumusan Masalah

Berdasarkan latar belakang yang telah diutarakan sebelumnya, maka masalah yang akan dikaji adalah diantaranya bagaimana merancang sistem dan memilih jenis data yang digunakan dalam membangun sistem identifikasi iris serta cara menerapkan/implementasi metode segmentasinya pupil dan iris dari gambar mata. Selain itu bagaimana mengukur performansi penerapan metode dan arsitektur dalam mengklasifikasikan data iris sehingga terbilang akurat.

1.3 Batasan Masalah

Lingkup yang menjadi batasan masalah dalam penelitian ini adalah data yang digunakan merupakan *dataset* iris yang diberikan pembimbing dan *dataset* iris Casia iris lamp, berupa gambar iris *grayscale* berukuran 640 x 480. Gambar iris tidak menyamping dan diambil dari arah depan seseorang tersebut. Pada tahap segmentasi, pencarian area iris berdasarkan penambahan piksel ke arah luar dari batas lingkaran pupil sebesar 36 piksel. Maksimum *epoch* pada pengujian arsitektur CNN dibatasi 2000 *epoch*.

1.4 Tujuan

Adapun tujuan yang akan dicapai dalam penelitian ini diantara lain adalah Menerapkan metode *Bitplane Slicing* dan *Convolutional Neural Network* (CNN) pada sistem pengenalan iris mata sehingga menghasilkan sistem identifikasi iris dari hasil implementasi kedua metode tersebut. Menganalisis hasil segmentasi yang dihasilkan oleh metode *Bitplane Slicing* yang mengacu pada parameter kernel, operasi erosi dan dilasi. Menghasilkan dan menganalisis arsitektur jaringan CNN yang dapat mengklasifikasikan iris dengan akurat.

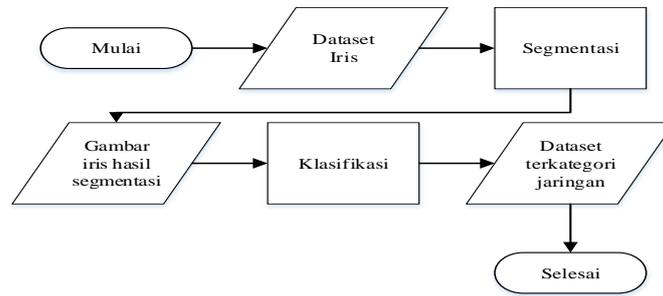
2. Studi Terkait

Dalam kajian yang berjudul *Image understanding for iris biometrics: A survey* yang disusun oleh Kevin W. Bowyer, Karen Hollingsworth, Patrick J. Flynn [1] menjelaskan konsep dasar *iris recognition* hingga *trend method* yang dilakukan sekarang. Awal mula iris recognition di pelopori oleh Daugman dimana tahapan segmentasi/lokalisasi dilakukan dengan menggunakan integrasi dan differensiasi untuk menentukan bentuk iris yang berupa lingkaran. Setelah proses segmentasi dilakukan, untuk menentukan ekstraksi ciri suatu citra pada metode Daugman ini menggunakan Metode Filter Gabor 2-D dan pada tahapan pencocokan ciri suatu citra menggunakan jarak Hamming (*Hamming Distance*). Dari awal mula itu muncul metode-metode yang baru seperti yang dilakukan oleh Wildes yaitu tahapan pada segmentasi/lokalisasi dapat dilakukan dengan Filter Gaussian Low pass. Sedangkan pada tahap ekstraksi ciri menggunakan metode Transformasi Hough, karena dapat menentukan parameter-parameter lingkaran dari pupil dan pada tahap pencocokan ciri iris dapat dilakukan dengan menggunakan Laplacian Filter Gaussian. Seterusnya muncul peneliti lain yang menggunakan metode yang lebih efisien dan kombinasi variatif dengan tujuan menambah performa sistem salah satunya penerapan *Bitplane*[1].

Penelitian yang lain dengan judul *Iris Recognition through Machine Learning Techniques* yang disusun oleh Maria De Marsico, Alfredo Petrosino dan Stefano Ricciardi [2] berisi tentang implementasi *machine learning* dalam *iris recognition*. Penelitian-penelitian sebelumnya masih banyak menggunakan metode *primitive* dan fokus terhadap pengembangan ekstraksi ciri. Machine learning belum sepenuhnya dilakukan pengembangan dalam aplikasinya terhadap pengenalan iris sehingga menjadikannya metode yang potensial untuk diteliti lebih lanjut. Penggunaan *Deep Learning* yang menjadi *potential research* membawa optimism baru untuk dikaji.

3. Perancangan Sistem

Gambaran umum mengenai sistem yang akan dibangun dapat dilihat pada general flowchart dibawah ini.



Gambar 1 Flowchart gambaran umum sistem

Secara umum gambaran sistem ini memiliki tiga proses utama yaitu proses mengolah data citra agar siap diolah melalui cara segmentasi, pelatihan jaringan CNN dan terakhir adalah pengujian jaringan CNN berdasarkan citra iris individu dengan menggunakan jaringan CNN yang sudah dilatih. Alur skenario yang akan diterapkan adalah data citra iris berupa *grayscale* akan diolah dengan segmentasi yang bermula dari homogenisasi *pixel*, lalu membagi citra ke dalam bentuk 8 bit-plane dan diambil *least significant bitplane*. Proses berlanjut dengan operasi morfologi yaitu erosi dan dilasi untuk mengetahui bagian tepi pupil dan lakukan standar deviasi terhadap vertikal dan horizontal sehingga mendapatkan tepian iris dan area iris. Data yang melalui serangkaian proses tadi lalu dimasukkan ke dalam jaringan CNN untuk melatih jaringan hingga jaringan siap untuk dilakukan pengujian dengan data citra individu yang berbeda

3.1 Dataset Iris

Dataset iris yang digunakan terdiri dari dua dataset, dataset pertama adalah dataset sejumlah pegawai di salah satu bandara berupa gambar iris berjumlah 98 *class*, dengan jumlah data, 3 data per *class* dan dataset ke dua adalah dataset iris Casia Lamp dengan jumlah data 404 *class*, dengan jumlah data 40 data per *class*, berupa gambar iris dari mata kanan dan kiri. Gambar tersebut berupa gambar 8 bit *grayscale*.

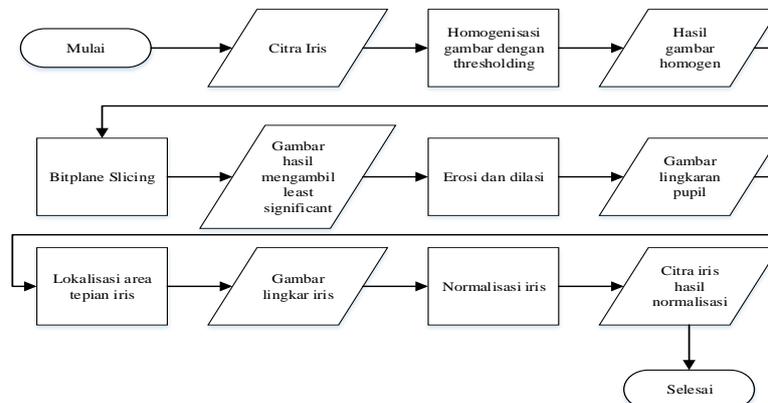
Tabel 3.1 Dataset iris

| Dataset | Jumlah Class | Class Dataset Segmentasi | Class Dataset Klasifikasi | Jumlah Data per Class |
|---------|--------------|--------------------------|---------------------------|-----------------------|
| Pertama | 98 | 50 | 25 | 3 |
| Ke dua | 404 | 50 | 25 | 20 |

Untuk data ke dua yaitu Iris Casia Lamp hanya menggunakan data dari mata kiri saja sehingga jumlah data hanya 20 data per *class* yang digunakan untuk pengujian. Penggunaan data klasifikasi diambil 25 *class* dari hasil proses segmentasi terbaik.

3.2 Segmentasi

Pada tahap segmentasi iris, ada beberapa tahapan yang harus dilakukan secara gambaran umumnya ada pada Gambar 3. Data yang akan digunakan dalam proses segmentasi berjumlah 50 *class* untuk masing – masing dataset, 3 data per *class* untuk dataset pertama dan, 20 data per *class* untuk dataset ke dua.



Gambar 2 Flowchart Segmentasi Iris

3.2.1 Homogenisasi Gambar

Proses pertama pada tahap ini adalah data berupa citra iris di atur setiap *pixel*-nya agar menghasilkan daerah citra yang *homogenous* untuk dapat dengan mudah mengidentifikasi pupil pada citra. Mengatur nilai *pixel* yang nilainya dibawah 60 dan diatas 240 menjadi 255 bertujuan lain untuk mengurangi efek dari pantulan cahaya yang mungkin terlihat pada area pupil. Area pupil yang cenderung kehitaman memungkinkan untuk mengambil asumsi area tersebut dikelilingi oleh intensitas *pixel* dibawah 60. Tidak sedikit pupil pada citra iris memiliki pantulan cahaya dari *flash* kamera sehingga ada sedikit *noise* putih pada area iris sehingga bisa diasumsikan area tersebut terdiri dari intensitas *pixel* diatas 240.

3.2.2 Bitplane Slicing

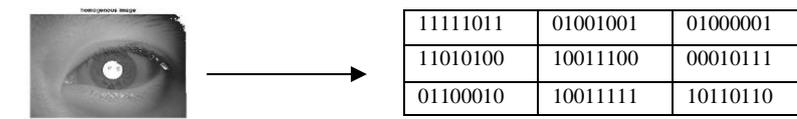
Setelah selesai mengatur nilai *pixel* dan diperoleh hasil citra yang telah *homogen*, proses selanjutnya adalah membagi citra ke bentuk *8-bit plane*. Teknik ini disebut dengan *bitplane slicing* karena mendekomposisi ulang suatu citra berdasarkan orde *bitplane* nya. Citra dibagi menjadi 8 lapisan *bit-plane* yaitu bermula dari *bitplane* ke-0 hingga *bit-plane* ke 7. Citra *grayscale* 8 bit yang bermula range nya dari [0,225] ditransformasi menjadi bentuk biner sehingga range berupa [0,1] dan diambil layer yang paling sedikit signifikannya terhadap komposisi suatu citra. Berikut tahapan *Bitplane Slicing* untuk detilnya.

A. Konversi Nilai Intensitas *Pixel* kedalam Bentuk Biner.

Pada tahapan pertama, *image input* dengan rentang nilai intensitas *pixel* 0 sampai 255 akan dikonversikan menjadi ke dalam bentuk biner. Tujuan konversi ke dalam bentuk biner ini untuk mendekomposisi citra yang nantinya dengan cara mengambil nilai *pixel* sesuai indeksnya dalam rentang indeks 8 bit yaitu 0 sampai 7.

B. Pengelompokan Nilai *Pixel* Berdasarkan Indeks.

Tahap selanjutnya adalah mengelompokkan setiap nilai-nilai intensitas *pixel* dalam bentuk biner berdasarkan indeksnya. Karena rentang indeks dimulai dari indeks 0 hingga indeks 8 maka citra yang telah dikonversikan terbagi menjadi 8 kelompok. Setiap indeks mewakili *slice* yang nantinya akan dilihat *slice* mana yang sedikit pengaruhnya atau signifikannya terhadap komposisi citra tersebut. Untuk lebih jelasnya akan dilihat dari ilustrasi seperti gambar berikut.



Gambar 3 Ilustrasi *Homogenous image* ke dalam bentuk biner

C. Memilih Least Significant Bitplane Sebagai Hasil Akhir.

Setelah proses dari dekomposisi *homogenous image* seperti sebelumnya atau dalam kata lain adalah *slicing*, proses selanjutnya adalah memilih *least significant bitplane* sebagai hasil akhir yang nantinya akan digunakan untuk proses selanjutnya.

3.2.3 Erosi dan Dilasi

Setelah diambil citra *bit-plane least significant layer*. Proses selanjutnya adalah proses operasi morfologi erosi dan dilasi. Proses tersebut adalah bertujuan untuk menghilangkan area *background* pada area sekitar objek sehingga hanya objek saja yang akan terlihat pada citra. Objek tersebut dalam arti lain adalah area pupil. Berikut tahapan detilnya.

A. Bordering

Tahapan pertama pada proses ini adalah *image input* yang dimana *image* tersebut adalah *least significant bitplane* yang sebagian area tepiannya akan ditutupi oleh *border* hitam pada keempat sisi. Tujuan dari penambahan area *border* ini dimaksudkan untuk mempertegas area *background* terhadap area objek yang dimana objek tersebut adalah area pupil. Sebagai contoh hasil dari proses ini akan ditunjukkan oleh gambar.

B. Pendefinisian Kernel

Sebelum menuju tahap *opening*, pendefinisian kernel yang nantinya sebagai *structuring element* akan digunakan sebagai basis kernel dalam operasi erosi dan dilasi selanjutnya. Pendefinisian kernel bertujuan untuk menentukan ukuran kernel yang akan digunakan pada operasi *hit*, *fit* dan *miss*. Pada penentuan ukuran kernel yang digunakan berupa *square* sebagai contoh untuk ukuran kernel 3 x 3.

| | | |
|---|---|---|
| 1 | 1 | 1 |
| 1 | 1 | 1 |
| 1 | 1 | 1 |

Gambar 4. Pendefinisian Kernel

C. Opening

Setelah mendefinisikan ukuran kernel dan terbentuk *structuring element* tahap selanjutnya adalah proses utama yaitu operasi erosi dan diteruskan dengan dilasi. Tujuan dari tahap ini adalah untuk *denoising*, yaitu mereduksi area derau di sekitar area objek. Area objek dalam hal ini adalah lingkaran pupil akan lebih difokuskan diantara area sekitarnya. Selain *denoising*, operasi ini bertujuan untuk *enchancing* berdasarkan sifat dari erosi yang *shrinking* dan dilasi yang *expanding* sehingga tepian area pupil yang dihasilkan lebih halus dan tidak terlalu destruktif.

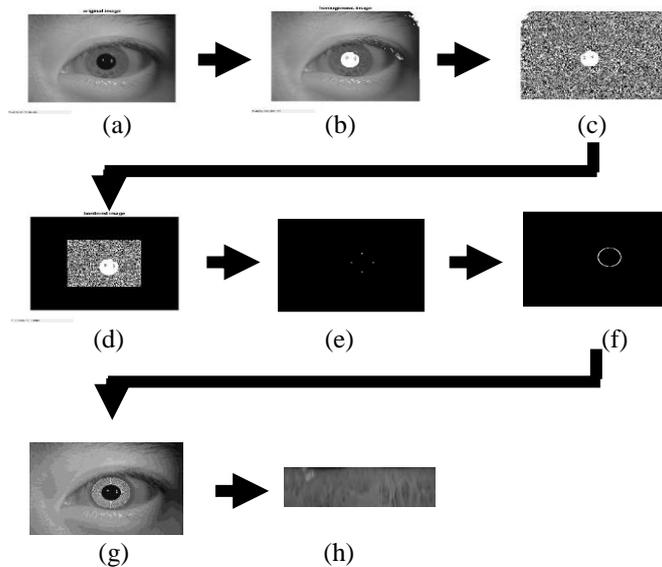
3.2.4 Lokalisasi Area Iris

Lokalisasi iris merupakan penentuan area iris dimana area iris berada di area luar tepi batas lingkaran pupil. Penentuan batas lingkaran pupil dengan cara penyusuran nilai array yang bernilai element 1. Nilai 1 merepresentasikan intensitas pixel. Penyusuran dilakukan dua arah yaitu secara baris dan kolom serta mencari titik terdekat dan terjauh sehingga diperoleh titik-titik tepi lingkaran pupil. Hasil kordinat dari titik-titik tersebut digunakan untuk mencari titik pusat area pupil beserta radius terjauh yang nantinya akan digunakan untuk membuat tepian lingkaran pupil. Lingkaran iris diperoleh dari hasil penambahan *pixel* dari tepian pupil kearah luar sebesar 36 *pixel*.

3.2.5 Normalisasi Iris

Normalisasi iris adalah tahapan dimana gambar asli yang telah di temukannya lingkaran pupil dan lingkaran iris akan di lakukan pemotongan dan dilakukan konversi, dari sistem koordinat kartesian menjadi sistem koordinat polar. Normalisasi iris ini di sebut juga Daugman Rubbersheet model, yang sudah menjadi standar untuk sistem klasifikasi iris, tujuan utama normalisasi iris, bukan hanya agar gambar *input* menjadi ukuran yang sama namun agar gambar iris, tidak dipengaruhi oleh dilatasi dan kontraksi pupil. Keluaran dari tahapan ini adalah gambar iris dengan ukuran yang sama, dalam pengerjaan ini ukurannya adalah 36 x 72.

Berikut hasil dari keseluruhan proses segmentasi yang dimuat oleh **Gambar 5** berikut.



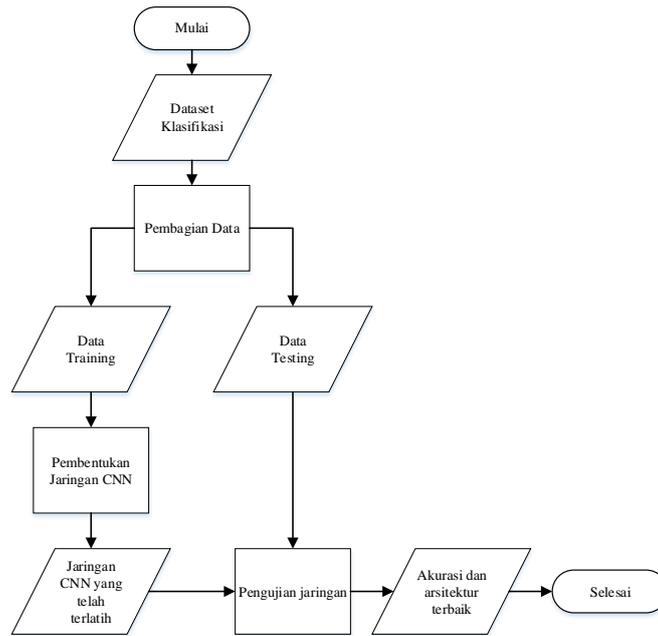
Gambar 5. Ilustrasi Proses Segmentasi

Dimana,

- (a) : gambar *input*,
- (b) : hasil proses dari *Homogenize Image*,
- (c) : hasil proses dari *Least Significant Bitplane*,
- (d) : hasil proses dari *Bordering*,
- (e) : hasil proses dari penentuan empat titik *endpoints*,
- (f) : hasil proses dari pembentukan lingkaran pupil,
- (g) : hasil proses *expanding by pixel* dari area asal pupil,
- (h) : hasil normalisasi Daugman Rubber sheet model, berukuran 36 x 72.

3.3 Klasifikasi

Klasifikasi iris dengan menggunakan algoritma CNN, memiliki beberapa tahapan yang harus dilakukan, beberapa tahapan tersebut dapat dilihat pada **Gambar 6**.



Gambar 6. Flowchart Klasifikasi

Pada klasifikasi tahapan yang pertama dilakukan adalah melakukan pembagian data, dari hasil segmentasi menjadi data *training* dan *data testing*, kemudian dilakukan pendefinisian arsitektur CNN yang akan digunakan, arsitektur yang akan digunakan pada tugas akhir ini ada pada **Tabel 2**.

Tabel 2. Arsitektur CNN

| Arsitektur 1 | Arsitektur 2 |
|--------------------------------|--------------------------------|
| Input Layer (36 x 72) | Input Layer (36 x 72) |
| Convolution Layer (5 x 9 x 30) | Convolution Layer (5 x 9 x 30) |
| ReLU | ReLU |
| Max Pooling layer (2 x 2) | Max Pooling layer (2 x 2) |
| Fully Connected Layer (25) | Convolution Layer (3 x 5 x 60) |
| Softmax | ReLU |
| Classification Layer | Max Pooling layer (2 x 2) |
| | Fully Connected Layer (25) |
| | Softmax |
| | Classification Layer |

| Arsitektur 3 | Arsitektur 4 |
|--------------------------------|--------------------------------|
| Input Layer (36 x 72) | Input Layer (36 x 72) |
| Convolution Layer (5 x 9 x 30) | Convolution Layer (5 x 9 x 30) |
| ReLU | ReLU |
| Max Pooling layer (2 x 2) | Max Pooling layer (2 x 2) |
| Fully Connected Layer (120) | Convolution Layer (3 x 5 x 60) |
| ReLU | ReLU |
| Fully Connected Layer (25) | Max Pooling layer (2 x 2) |
| Softmax | Fully Connected Layer (120) |
| Classification Layer | ReLU |
| | Fully Connected Layer (25) |
| | Softmax |
| | Classification Layer |

Setelah penyusunan arsitektur CNN, dilanjutkan oleh penentuan pengisian bobot dan bias awal untuk jaringan, pengisian bobot awal yang digunakan adalah random dengan biasnya adalah 0, kemudian dilakukan penentuan *learning rate*, *learning rate* yang digunakan adalah sebesar 0.0001. Epoch maksimal yang digunakan pada saat *learning* berada pada 2000 Epoch.

Perbedaan konfigurasi *layer* penyusun pada setiap arsitektur bertujuan untuk mengetahui efek dan pengaruhnya dari setiap penambahan *layer* yang berbeda. Arsitektur pertama merupakan arsitektur dasar atau *basis* dimana susunan konfigurasi setiap *layer* tidak ada penambahan atau pengulangan jenis *layer*. Sedangkan arsitektur kedua diberikan penambahan jenis *upper layer* yaitu konvolusi, aktivasi dan *max pooling*. Tujuannya penambahan *upper layer* untuk memberikan kinerja ekstra terhadap jaringan dalam menghasilkan variasi *feature image* atau ciri khusus citra baru seperti pola yang lebih banyak. Sedangkan untuk arsitektur ketiga diberikan penambahan jenis *bottom layer* yaitu jaringan *fully-connected* yang bertujuan untuk normalisasi data matriks multidimensi kedalam bentuk array yang lebih sederhana dengan jumlah koneksi bobot terhadap *neuron* atau unit pemrosesan lebih banyak, sehingga nilai-nilai bobot yang berpengaruh terhadap degradasi nilai error lebih banyak. Sedangkan untuk arsitektur keempat merupakan gabungan dari penambahan arsitektur kedua dan ketiga. Dalam skema seperti ini, besaran pengaruh kompleksitas arsitektur jaringan CNN dan pencarian arsitektur terbaik akan lebih teroganisir.

Tahap selanjutnya data tahap *training* akan di proses untuk melatih jaringan CNN dengan algoritma pembelajaran menggunakan *backpropagation* untuk pembaharuan setiap bobot dan bias pada jaringan CNN hingga memenuhi nilai *threshold error* atau maximum *epoch* yang di harapkan, setelah pelatihan pada jaringan selesai, akan terbentuk bobot dan bias yang siap digunakan untuk klasifikasi data *testing* dan pengujian jaringan CNN.

4. Pembahasan

Pada proses pengujian, akan dilakukan beberapa pengujian berupa pencarian parameter segmentasi iris untuk masing masing *dataset*, agar mendapatkan hasil segmentasi yang tepat, dan kemudian akan dilanjutkan dengan pengujian beberapa arsitektur CNN yang berbeda untuk klasifikasi iris.

4.1 Skenario Pengujian

Pengujian yang akan dilakukan berdasarkan dua skenario seperti berikut.

1. Skenario pertama, memilih 50 class data dari masing – masing data set, kemudian mencari, dan menganalisis pengaruh parameter pendefinisian ukuran structuring element, jumlah erosi, dan jumlah dilasi guna mendapatkan akurasi segmentasi terbaik untuk masing-masing dataset, dengan parameter awal yang digunakan adalah kernel structuring element = 3x3, jumlah erosi = 1 kali, jumlah dilasi = 1 kali.
2. Skenario ke dua, memilih 25 class dari setiap *dataset* untuk pengujian klasifikasi CNN, dan membagi data menjadi data training dan data testing, 2 Data training 1 Data testing untuk *dataset* pertama, dan 15 data training 5 data testing untuk *dataset* ke dua. Kemudian melakukan pengujian arsitektur CNN untuk mencari arsitektur CNN terbaik, dengan 4 arsitektur yang berbeda, sesuai dengan **Tabel 2**.

4.2 Hasil Pengujian Segmentasi

Hasil pengujian berupa parameter-parameter dengan hasil segmentasi terbaik untuk data set pertama dan kedua. Setelah serangkaian hasil proses segmentasi dengan variasi inputan parameter, didapatkan hasil pengujian parameter untuk masing-masing *dataset* seperti yang tercantum dalam **Tabel 3**.

Tabel 3. Perbandingan Parameter

| Dataset 1 | | | | Dataset 2 | | | | Dataset 1 | | | | Dataset 2 | | | |
|-----------|-------|--------|---------|-----------|-------|--------|---------|-----------|-------|--------|---------|-----------|-------|--------|---------|
| Kernel | Erosi | Dilasi | Akurasi |
| 3x3 | 1 | 1 | 47% | 3x3 | 1 | 1 | 54% | 7x7 | 1 | 1 | 51% | 7x7 | 1 | 1 | 69% |
| | 1 | 2 | 44% | | 1 | 2 | 62% | | 1 | 2 | 49% | | 1 | 2 | 77% |
| | 1 | 3 | 42% | | 1 | 3 | 55% | | 1 | 3 | 50% | | 1 | 3 | 73% |
| | 2 | 1 | 62% | | 2 | 1 | 80% | | 2 | 1 | 71% | | 2 | 1 | 93% |
| | 2 | 2 | 79% | | 2 | 2 | 79% | | 2 | 2 | 75% | | 2 | 2 | 98% |
| | 2 | 3 | 80% | | 2 | 3 | 82% | | 2 | 3 | 77% | | 2 | 3 | 94% |
| | 3 | 1 | 64% | | 3 | 1 | 72% | | 3 | 1 | 54% | | 3 | 1 | 82% |
| | 3 | 2 | 55% | | 3 | 2 | 77% | | 3 | 2 | 55% | | 3 | 2 | 88% |
| | 3 | 3 | 53% | | 3 | 3 | 67% | | 3 | 3 | 57% | | 3 | 3 | 87% |
| Dataset 1 | | | | Dataset 2 | | | | Dataset 1 | | | | Dataset 2 | | | |
| Kernel | Erosi | Dilasi | Akurasi |
| 5x5 | 1 | 1 | 55% | 5x5 | 1 | 1 | 67% | 9x9 | 1 | 1 | 46% | 9x9 | 1 | 1 | 65% |
| | 1 | 2 | 58% | | 1 | 2 | 59% | | 1 | 2 | 49% | | 1 | 2 | 57% |
| | 1 | 3 | 49% | | 1 | 3 | 72% | | 1 | 3 | 43% | | 1 | 3 | 54% |
| | 2 | 1 | 65% | | 2 | 1 | 88% | | 2 | 1 | 69% | | 2 | 1 | 76% |
| | 2 | 2 | 82% | | 2 | 2 | 93% | | 2 | 2 | 75% | | 2 | 2 | 82% |
| | 2 | 3 | 77% | | 2 | 3 | 82% | | 2 | 3 | 72% | | 2 | 3 | 85% |
| | 3 | 1 | 42% | | 3 | 1 | 74% | | 3 | 1 | 66% | | 3 | 1 | 64% |
| | 3 | 2 | 52% | | 3 | 2 | 81% | | 3 | 2 | 59% | | 3 | 2 | 75% |
| | 3 | 3 | 62% | | 3 | 3 | 84% | | 3 | 3 | 55% | | 3 | 3 | 79% |

4.2.1 Hasil Analisis Parameter Segmentasi

Pengaruh jenis dan ukuran kernel terhadap proses segmentasi mempengaruhi jangkauan area yang akan diproses oleh operasi *hit,fit* dan *miss*. Semakin besar akan semakin luas jangkauannya namun kurang ideal untuk gambar ukuran dan area objek yang kecil bahkan bisa terjadi *overfitting*. Berbeda jika terlalu kecil, *noise* tidak akan tereduksi dengan baik dan penegasan objek yang difokuskan tidak optimal.

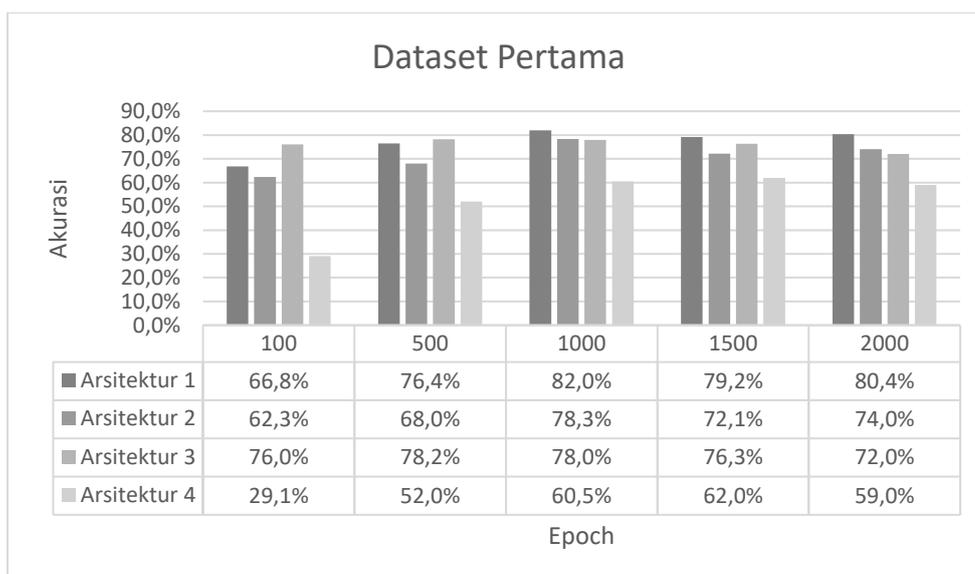
Pengaruh jumlah erosi dan dilasi sangat berpengaruh pada proses pencarian titik tepian pupil. Semakin besar jumlah erosi semakin optimal dalam pembiasan *noise* dan semakin banyak jumlah dilasi semakin optimal dalam memfokuskan objek atau dalam kata lain *growing*. Namun perlu diperhatikan ketika objek yang akan difokuskan terlalu kecil, jumlah erosi yang banyak bisa berdampak fatal karena objek akan bias oleh operasi tersebut dan dari erosi yang tidak optimal akan menyisakan *noise* kecil yang kemungkinan akan timbul terbuka kembali karena proses dilasi yang terlalu intensif. Parameter terbaik didapati seperti **Tabel 4**.

Tabel 4. Parameter terbaik

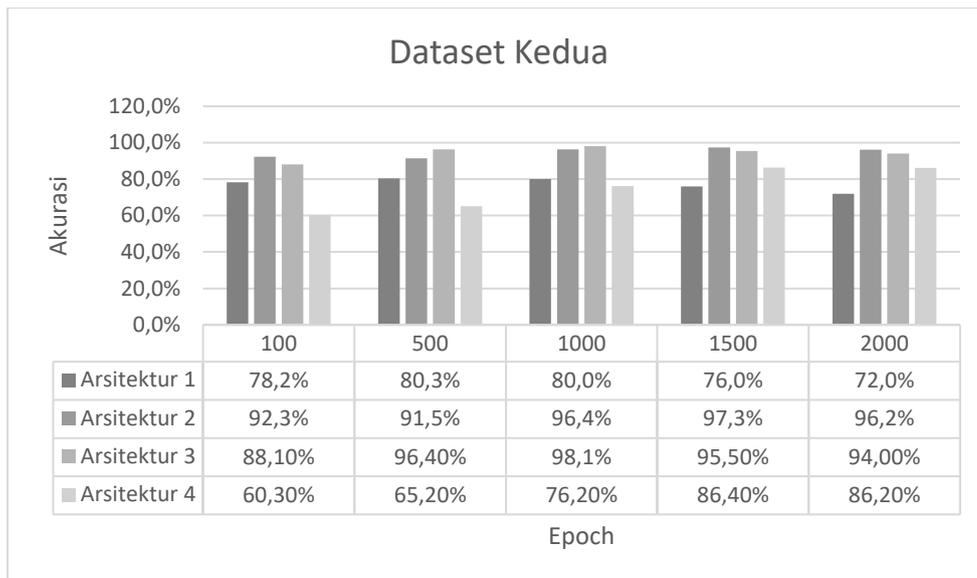
| Dataset 1 | | Akurasi | Dataset 2 | | Akurasi |
|-----------|--------------|---------|-----------|--------------|---------|
| Kernel | Square (5x5) | 82% | Kernel | Square (7x7) | 98% |
| Erosi | 2 | | Erosi | 2 | |
| Dilasi | 2 | | Dilasi | 2 | |

4.3 Hasil Pengujian Klasifikasi

Hasil pengujian berupa arsitektur penyusun jaringan CNN dengan hasil klasifikasi terbaik untuk data set pertama dan kedua. Setelah serangkaian hasil proses klasifikasi dengan variasi kombinasi *layer* penyusun jaringan, didapatkan hasil arsitektur terbaik untuk masing-masing *dataset* seperti yang tercantum dalam **Gambar 7** dan **Gambar 8**.



Gambar 7. Hasil Pengujian Klasifikasi Dataset Pertama



Gambar 8. Hasil Pengujian Dataset Kedua

4.3.1 Hasil Analisis Pengujian Klasifikasi

Hasil Pengujian diperoleh hasil perhitungan dengan akurasi terbaik pada setiap arsitektur dan konfigurasi arsitektur terbaik untuk masing-masing data bisa saja berbeda. Berikut hasil akurasi terbaik untuk masing-masing data dan arsitektur.

Tabel 6. Hasil Perhitungan Terbaik Setiap Arsitektur

| Dataset Pertama | | | Dataset Kedua | | |
|-----------------|---------|-------|---------------|---------|-------|
| Arsitektur | Akurasi | Epoch | Arsitektur | Akurasi | Epoch |
| Pertama | 82,00% | 1000 | Pertama | 80,30% | 500 |
| Kedua | 78,30% | 1000 | Kedua | 97,30% | 1500 |
| Ketiga | 78,20% | 500 | Ketiga | 98,10% | 1000 |
| Keempat | 62,00% | 1500 | Keempat | 86,40% | 1500 |

Pengaruh konfigurasi setiap arsitektur mempengaruhi pada setiap hasil perhitungan, untuk konfigurasi *layer* yang lebih ringkas seperti arsitektur pertama diperoleh hasil yang lebih baik untuk *dataset* pertama dibanding *layer* lainnya. Hal ini disebabkan karena konfigurasi arsitektur yang terlalu kompleks menyebabkan jaringan *overfitting* terhadap data inputan yang lebih sedikit. Berbeda dengan *dataset* kedua yang jauh lebih banyak, perhitungan akurasi terbaik diperoleh oleh arsitektur ketiga. Hal ini disebabkan karena *dataset* kedua lebih banyak jumlah data trainingnya sehingga diperlukan variasi fitur yang lebih beragam untuk bisa mendapatkan akurasi saat klasifikasi lebih baik. Epoch mempengaruhi dalam proses *learning*, semakin banyak Epoch yang dilakukan maka jaringan akan lebih kaku karena hasil output jaringan lebih cenderung menyesuaikan persis terhadap target output sehingga performa jaringan saat klasifikasi menurun. Epoch yang optimum untuk penelitian ini diperoleh dengan range dari 1000 hingga 1500 Epoch.

5. Kesimpulan

Dari hasil pengujian beberapa parameter segmentasi dan arsitektur CNN untuk masing-masing *dataset* iris, diperoleh kesimpulan diantara lain adalah

1. proses homogenisasi dalam penentuan *threshold* bergantung kepada kontras dan pencahayaan gambar yang akan diproses, semakin kontras maka proses *thresholding* semakin baik dikarenakan perbedaan warna pada setiap area lebih signifikan. Namun apabila pencahayaan terlalu gelap atau terlalu terang, proses *thresholding* akan cenderung lebih sulit dan melebar kepada area area yang tidak perlu. Hal ini disebabkan karena setiap area memiliki perbedaan intensitas yang tidak terlalu jauh.
2. Nilai parameter ukuran dan jenis kernel *structuring element* pada operasi erosi dan dilasi dapat berpengaruh terhadap jangkauan area pada saat operasi *hit*, *fit*, dan *miss* terhadap citra asli. Semakin besar ukuran kernel maka area jangkauan semakin luas, hal ini berguna untuk proses *denoising* sehingga tidak ada lagi *noise* yang tersisa. Namun perlu diperhatikan untuk objek yang akan difokuskan apabila objek terlalu kecil, proses erosi akan menghilangkan objek tersebut dan berakibat tidak ada area bagian pupil untuk dibangkitkan kembali oleh dilasi.
3. Penentuan titik tepian area pupil sangat bergantung pada operasi *opening* sebelumnya. Apabila citra yang diproses masih memiliki *noise* walaupun setitik akan menyebabkan pencarian nilai intensitas bernilai 1 akan keliru. Hal ini disebabkan karena array hanya menyimpan kordinat *pixel* dengan nilai intensitas 1 berdasarkan jarak terdekat dan terjauh.
4. Kompleksitas jaringan CNN bergantung pada jumlah data yang diproses. Jumlah data yang lebih sedikit cenderung optimal untuk arsitektur dasar yang sederhana dan untuk data yang lebih banyak perlu sedikitnya konfigurasi yang lebih *advance* dengan penambahan *upper layer* atau *bottom layer* yang bertujuan untuk proses pembelajaran yang lebih mendalam atau *deep learning*.
5. Jumlah Epoch tidak selalu menentukan hasil akurasi. Apabila Epoch yang dilakukan terlalu banyak, jaringan akan lebih cenderung kaku sehingga pada saat proses *testing* klasifikasi data akan mengalami. Jaringan yang akan terbentuk menghasilkan output yang hampir sama persis seperti target output, sehingga jika diberikan variasi *feature* citra berbeda sebagai data input jaringan tidak bisa mengidentifikasi. Penentuan jumlah Epoch sedikit *arbitrary* dikarenakan setiap arsitektur jaringan berbeda-beda dalam kecepatan menurunkan nilai error. Pada kasus tertentu seringkali ditemukannya nilai minimum lokal dikarenakan jumlah Epoch yang kurang sehingga potensi jaringan dalam proses pembelajaran tidak optimal.
6. Hasil parameter segmentasi terbaik untuk *dataset* pertama adalah kernel 5x5, jumlah erosi 2 dan jumlah dilasi 2. Sedangkan untuk *dataset* kedua adalah kernel 7x7, jumlah erosi 2 dan jumlah dilasi 2. Arsitektur CNN terbaik untuk *dataset* pertama adalah arsitektur pertama dengan nilai akurasi 82% dan Epoch sebanyak 1000 sedangkan untuk *dataset* kedua adalah arsitektur ketiga dengan nilai akurasi 98,1% dan jumlah Epoch 1000.

Daftar Pustaka

- [1] W.Bowyer, Kevin. Hollingsworth. Karren, J.Flynn, Patrick, 2007. *Image Understanding for Iris Biometrics: A Survey*. USA : Department of Computer Science and Engineering, University of Notre Dame
- [2] De Marsico. Maria, Petrosino. Alfredo, Ricciardi. Stefano, 2016. *Iris Recognition through Machine Learning Techniques : A Survey*. ITALY : Department of Informatics, Universe of Rome.
- [3] Sinharoy, Indranil. *Iris Anatomy*. Digital image. *Indranilsinharoy*. N.p., 5 Dec. 2014. Web. 22 Oct. 2016.
- [4] J.Daugman, 2004. *How Iris Recognition Works*, IEEE Transaction on Circuit and Systems for video technology vol. 14, No. 1, pp. 21-30. USA : IEEE.
- [5] Nugroho. Eko, 2008. *Biometrik (Pengenalan)*. Jakarta: Penerbit Medio.
- [6] Bonney. Bradford, Ives. Robbert, Elter. Delores, Du. Yingzi, 2004. *Iris Pattern Extraxtion Using Bit Planes and Standard Deviations*. Annapolis: US Naval Academy.
- [7] D.Kumar. Srivinas, G.Ramaswamy,D.Ravikiran, Rani. P.Sirisha, 2009. *A Novel Approach For An Accurate Human Identification Through Iris Recognition Using Bitplane Slicing and Normalisation*. India: Jatit.
- [8] Naser. Jawas, Suciati. Nanik,. 2013. *Image Inpainting using Erosion and Dilation Operation* vol.51. Surabaya : Department of informatics, Faculty Information Technology, Institut Teknologi Sepuluh November (ITS).
- [9] Munir. R, 2004. *Pengolahan Citra Digital*. Bandung : Penerbit Informatika.
- [10] Sulilman. Alaeldin, Zhang. Yun, 2015. *A Review on Back-Propagation Neural Networks in the Application of Remote Sensing Image Classification*. Kanada : University of New Brunswick.
- [11] Rohrer, Brandon. "Data Science and Robots Blog." Blog post. *How Do Convolutional Neural Networks Work*. N.p., 18 Aug. 2016. Web. 22 Oct. 2016.
- [12] Lawrence. Steves, Lee Giles. C, Tsoi. Chung Ah, D.back. Andrew,. *Face Recognition : A Convolutional Neural Network Approach*. Australia : Electrical and Computer Engineering, University of Quensland.
- [13] Oravec. Milos, 2014. *Feature Extraction and Classification by Machine Learning Methods for Biometric Recognition of Face and Iris*. Slovak : Faculty of Electrical Engineering and Information Technology, Slovak University of Technology.
- [14] De Marsico, Maria, Alfredo Petrosino, and Stefano Ricciardi. "Iris Recognition through Machine Learning Techniques: a Survey." *Pattern Recognition Letters* (2016).