

# PENGENALAN WAJAH MAHASISWA UNIVERSITAS NURUL JADID PADA VIDEO MENGGUNAKAN METODE *HAAR CASCADE* DAN *DEEP LEARNING*

Gulpi Qorik Oktagalu Pratamasunu<sup>1)</sup>, Olief Ilmandira Ratu Farisi<sup>2)</sup>,  
Maulidil Jannah<sup>3)</sup>

Prodi Informatika Fakultas Teknik Universitas Nurul Jadid

Karanganyar Paiton Probolinggo

e-mail: [gulpi.qorik@gmail.com](mailto:gulpi.qorik@gmail.com)<sup>1)</sup>, [olief.ilmandira@gmail.com](mailto:olief.ilmandira@gmail.com)<sup>2)</sup>, [Maulidijannah22@gmail.com](mailto:Maulidijannah22@gmail.com)<sup>3)</sup>

## ABSTRAK

Pengenalan wajah merupakan suatu teknologi dari komputer untuk mengidentifikasi wajah seseorang pada suatu gambar maupun video. Banyak metode yang bisa digunakan untuk pengenalan wajah antara lain metode *fisherface*, *local binary pattern histogram*, dan *eigenface*. Peneliti sebelumnya menerapkan pengenalan wajah menggunakan metode *eigenface* untuk mengidentifikasi wajah mahasiswa di Universitas Nurul Jadid. Akan tetapi, metode *eigenface* hanya fokus pada citra dengan objek tidak bergerak, sehingga belum bisa diterapkan pada video. Untuk itu, pada penelitian ini diusulkan suatu metode yang dapat mengidentifikasi wajah pada video yaitu metode *haar cascade* dan *deep learning*. Metode *haar cascade* merupakan suatu metode yang dapat mendeteksi posisi letak wajah pada suatu video dan metode *deep learning* untuk mengenali wajah yang sudah terdeteksi pada video. Hasil uji coba yang dilakukan metode *haar cascade* dapat mendeteksi adanya wajah pada video secara baik. Akan tetapi metode *haar cascade* juga mendeteksi yang bukan wajah pada data *testing*. Hasil dari uji coba pada gambar dengan metode *haar cascade* dan *deep learning* teridentifikasi secara benar dengan tingkat akurasi 99,6%. Hasil uji coba metode *haar cascade* dan *deep learning* pada video mahasiswa berhasil dilakukan jika komposisi warna dan tingkat cahayanya sama dengan data *training* dan jika tidak sesuai dengan data *training* maka tidak berhasil mengidentifikasi wajah mahasiswa pada video secara benar.

**Kata Kunci** : *Pengenalan Wajah, Haar Cascade, Deep Learning.*

## 1. PENDAHULUAN

Perkembangan teknologi pada saat ini begitu pesat, khususnya dalam dunia teknologi informasi. Teknologi yang semakin pesat berkembang membantu manusia melakukan pekerjaan yang lebih mudah dan tidak memakan waktu lama. Akhir-akhir ini penerapan pola di banyak negara semakin pesat berkembang, karena penerapan pola sangat bermanfaat untuk keamanan suatu perusahaan maupun instansi khususnya di negara maju maupun negara berkembang. Salah satunya yaitu pengenalan wajah (*Face Recognition*) secara otomatis.

Pengenalan wajah secara otomatis merupakan suatu teknologi dari komputer untuk mengidentifikasi wajah seseorang pada suatu gambar digital maupun video. Banyak metode yang bisa digunakan untuk pengenalan wajah antara lain metode *fisherface*, *local binary pattern histogram*, dan *eigenface*.

Pada 2018, Ika Fitriyatul Mukaromah telah meneliti tentang pengenalan wajah dengan judul "*Face Recognition* Mahasiswa

Universitas Nurul Jadid (UNUJA) dengan metode *Eigenface*." Pada penelitian tersebut, pengenalan wajah yang dilakukan menggunakan metode *eigenface*. Pengenalan wajah pada Mahasiswa dengan menerapkan metode *eigenface* tersebut berhasil dilakukan dengan 3 jenis data uji. Pertama, metode *eigenface* tersebut berhasil mengidentifikasi gambar wajah mahasiswa yang menghadap ke depan secara baik dengan tingkat akurasi 100%. Kedua, metode tersebut memiliki tingkat akurasi 73% pada saat digunakan untuk mengidentifikasi wajah miring dan ketiga metode *eigenface* tersebut memiliki tingkat akurasi 66% untuk data uji wajah yang menghadap ke samping.

Pada penelitian tersebut, metode *eigenface* dapat mengidentifikasi gambar wajah mahasiswa yang menghadap ke depan secara baik. Akan tetapi, metode tersebut memiliki tingkat akurasi yang rendah pada saat digunakan untuk mengidentifikasi wajah yang menghadap ke samping. Selain itu, penelitian tersebut hanya fokus pada citra dengan objek

tidak bergerak, sehingga belum bisa diterapkan pada video.

Paul Viola pada 2001 mengusulkan metode yang disebut *haar cascade* untuk mendeteksi objek pada video. Metode ini menggunakan pendekatan *machine learning* dimana fungsi *cascade* dilatih dari banyak citra positif dan citra negatif. Metode *haar cascade* ini dapat digunakan untuk mendeteksi posisi letak wajah pada suatu video. Tetapi untuk mengenali wajah dibutuhkan metode lain diantaranya adalah *eigenface*, *fisherface*, *local binary pattern histogram*, dan *machine learning*.

*Deep learning* merupakan cabang dari *machine learning* yang terinspirasi dari *kortex* manusia dengan menerapkan jaringan syaraf buatan yang memiliki banyak *hidden layer* (Santoso, Ariyanto, 2018). Metode *deep learning* telah digunakan di berbagai macam penerapan diantaranya yaitu deteksi kecacatan permukaan buah, penerjemahan bahasa, dan sebagainya. Oleh karena itu, pada penelitian ini diusulkan metode pengenalan wajah pada video menggunakan metode *haar cascade* dan *deep learning*.

Berdasarkan permasalahan di atas, judul skripsi yang akan diambil pada penelitian ini adalah “Pengenalan Wajah Mahasiswa Universitas Nurul Jadid pada Video Menggunakan Metode *Haar Cascade* dan *Deep Learning*.” Dengan penelitian ini diharapkan proses identifikasi wajah mahasiswa Universitas Nurul Jadid pada video dengan menggunakan metode *haar cascade* dan *deep learning* mendapatkan hasil yang efektif dan akurat.

## 2. STUDI PUSTAKA

### 2.1. Penelitian Terkait

Ika Fitriyatul Mukaromah (2018) melakukan penelitian yang berjudul “*Face Recognition Mahasiswa Universitas Nurul Jadid (UNUJA) dengan metode Eigenface*”. Permasalahan yang terjadi yaitu bagaimana membuat suatu sistem yang dapat mengenali wajah mahasiswa UNUJA secara otomatis dan efektif karena Universitas Nurul Jadid belum menerapkan *face recognition* yang dapat memberikan manfaat dalam pelayanan akademik maupun sistem keamanan kampus. Metode untuk pengenalan wajah mahasiswa Universitas Nurul Jadid (UNUJA) pada penelitian tersebut menggunakan *Eigenface*.

Adapun hasil yang dicapai yaitu metode pengenalan wajah pada mahasiswa UNUJA.

Aries Suharso (2016) melakukan penelitian yang berjudul “*Pengenalan Wajah Menggunakan Metode Viola-Jones dan Eigenface Dengan Variasi Posisi Wajah Berbasis Webcam*”. Permasalahan yang terjadi yaitu walaupun telah banyak dilakukan pengembangan pada deteksi dan pengenalan wajah namun hasilnya masih jauh dari kesempurnaan, terlebih masih sedikit yang membahas tentang deteksi citra wajah manusia berdasarkan variasi posisi wajah. Jadi variasi posisi wajah yang akan diteliti yaitu menggunakan Metode *Viola-Jones* untuk mendeteksi wajah dan metode *Eigenface* untuk mengenali wajah tersebut. Pengujian aplikasi dilakukan melalui dua tahap, yaitu pengujian berdasarkan variasi sudut pengambilan citra wajah dan pengujian berdasarkan nilai *threshold*. Hasil yang dicapai oleh penelitian tersebut yaitu dapat mendeteksi wajah pada *webcam* dengan berbagai variasi posisi wajah manusia.

Sayeed Al-Aidid, dkk (2018) melakukan penelitian yang berjudul “*Sistem Pengenalan Wajah dengan Algoritma Haar Cascade dan Local Binary Pattern Histogram*”. Permasalahan yang terjadi yaitu aplikasi dari pengenalan wajah semakin meningkat beberapa tahun ini, namun beberapa metode yang digunakan masih belum optimal. Untuk mengatasi hal tersebut peneliti mendeteksi wajah menggunakan metode *Haar Cascade* dan *Local Binary Pattern Histogram* sebagai pengenalan wajah. Sistem ini menggunakan *webcame* sebagai kamera dan *library* dari *OpenCV*. Hasil yang telah diperoleh yaitu sistem dapat mengenali wajah dari enam orang subjek yang telah terdaftar dalam *database*, baik sendiri maupun berkelompok dalam satu *frame*.

Denny Hardiyanto, dkk (2018) melakukan penelitian yang berjudul “*Optimalisasi Metode Deteksi Wajah berbasis Pengolahan Citra untuk Aplikasi Identifikasi Wajah pada Presensi Digital*”. Permasalahan yang terjadi adalah presensi kehadiran mahasiswa di kampus yang sifatnya masih manual sehingga tidak sedikit mahasiswa yang melakukan kecurangan pada saat presensi. Jadi penelitian ini bertujuan untuk menerapkan presensi otomatis untuk kehadiran mahasiswa. Metode yang diusulkan untuk penelitian ini antara lain : *Viola-Jones*,

ekstraksi fitur menggunakan 12 fitur statistika warna, dan *Klasifier Multy Layer Perceptron*. Diharapkan dengan beberapa metode yang diusulkan dapat menemukan teknik/metode yang paling tepat dalam mendeteksi citra wajah dan dapat mengurangi kesalahan deteksi (*false positive*) pada objek non-wajah di ruang kelas. Adapun hasil yang dicapai pada penelitian tersebut menghasilkan sebuah sistem presensi otomatis untuk kehadiran mahasiswa.

Aditya Santoso, dkk (2018) melakukan penelitian yang berjudul “**Implementasi Deep Learning berbasis Keras untuk Pengenalan Wajah**”. Permasalahan yang terjadi yaitu ada beberapa faktor yang mempengaruhi sistem pengenalan wajah antara lain faktor pencahayaan, ekspresi wajah dan perubahan atribut pada wajah. Untuk mengatasi permasalahan tersebut peneliti menggunakan metode *Deep Learning* dengan model *Convolutional Neural Network* (CNN) untuk mencoba mengatasi permasalahan tersebut dalam pengenalan wajah. Pengimplementasian CNN pada penelitian ini menggunakan *library keras* dan menggunakan bahasa pemrograman *Python*.

Hasil dari penelitian ini mencapai tingkat akurasi yang tinggi yaitu sebesar 98,57%. Dari 30 data *testing*, hampir semua memiliki kecocokan dengan *database* yang ada. Ukuran dari gambar pada saat proses *training* mempengaruhi tingkat akurasi dan waktu pelatihan data. Penggunaan jumlah *layer* pada proses *training* juga mempengaruhi tingkat akurasi saat dilakukan uji coba. Jika semakin banyak *layer* yang digunakan pada *Convolutional Neural Network* (CNN) saat proses *training* maka semakin baik hasil yang akan didapatkan.

## 2.2. Dasar Teori


### A. Haar Cascade

*Haar cascade* adalah metode pendeteksian objek yang efektif yang diusulkan Paul Viola. Metode ini menggunakan pendekatan *machine learning* dimana fungsi *cascade* dilatih dari banyak gambar positif dan gambar negatif. Gambar ini yang digunakan untuk mendeteksi objek pada gambar lainnya. Metode ini menggunakan *haar-like features* dimana perlu dilakukan *training* terlebih dahulu untuk mendapatkan suatu pohon keputusan dengan nama *cascade classifier* sebagai penentu apakah ada objek

atau tidak dalam tiap *frame* yang di proses (Astini, 2018).

### 1. Haar like feature

*Haar like feature* atau yang dikenal sebagai *Haar Cascade Classifier* merupakan *rectangular* (persegi) *feature*, yang memberikan indikasi secara spesifik pada sebuah gambar atau *image*. *Haar cascade classifier* berasal dari gagasan Paul Viola dan Michael Jhon, karena itu dinamakan metode Viola & Jhon. Ide dari *Haar like feature* adalah mengenali obyek berdasarkan nilai sederhana dari fitur tetapi bukan merupakan nilai *pixel* dari *image* obyek tersebut. Metode ini memiliki kelebihan yaitu komputasi yang sangat cepat, karena hanya tergantung pada jumlah *pixel* dalam persegi bukan setiap nilai *pixel* dari sebuah *image*. Metode ini merupakan metode yang menggunakan statistikal model (*classifier*). Adapun contoh *Haar like feature* ditunjukkan pada Gambar 1. Pendekatan untuk mendeteksi objek dalam gambar menggabungkan empat kunci utama yaitu *Haar like feature*, *Integral Image*, *Adaboost learning* dan *Cascade Classifier* (Kusumanto, dkk, 2012).



Gambar 1 Haar Like Feature

*Haar Feature* adalah fitur yang didasarkan pada *Wavelet Haar*. *Wavelet Haar* adalah gelombang tunggal bujur sangkar (satu interval tinggi dan satu interval rendah). Untuk dua dimensi, satu terang dan satu gelap. Selanjutnya kombinasi-kombinasi kotak yang digunakan untuk pendeteksian objek visual yang lebih baik. Setiap *Haar-like feature* terdiri dari gabungan kotak - kotak hitam dan putih (Syarif dan Wijanarto, 2015).


$$f(x) = \text{sumblack rectangle} - \text{sumwhite rectangle} \quad (1)$$

Adanya fitur *Haar* ditentukan dengan cara mengurangi rata-rata *pixel* pada daerah gelap dari rata-rata *pixel* pada daerah terang.

Jika nilai perbedaannya itu diatas nilai ambang atau *threshol*d, maka dapat dikatakan bahwa fitur tersebut ada. Nilai dari *Haar-like feature* adalah perbedaan antara jumlah nilai - nilai *pixel* satu *gray level* dalam daerah kotak hitam dan daerah kotak putih. dimana untuk kotak pada *Haar like feature* dapat dihitung secara cepat menggunakan “*integral image*” (Syarif dan Wijanarto, 2015).

**2. Integral Image**

*Integral Image* digunakan untuk menentukan ada atau tidaknya dari ratusan fitur *Haar* pada sebuah gambar dan pada skala yang berbeda secara efisien.



**Gambar 2** *Integral Image*

Seperti yang ditunjukkan oleh Gambar 2 setelah pengintegrasian, nilai pada lokasi *pixel* (x, y) berisi jumlah dari semua *pixel* di dalam daerah segiempat dari kiri atas sampai pada lokasi (x, y) atau daerah yang diarsir. Guna mendapatkan nilai rata-rata *pixel* area segiempat (daerah yang diarsir) ini dapat dilakukan hanya dengan membagi nilai pada (x, y) oleh area segiempat. dimana *ii*(x, y) adalah *integral image* dan *i*(x, y) adalah *original image* (Syarif dan Wijanarto, 2015).

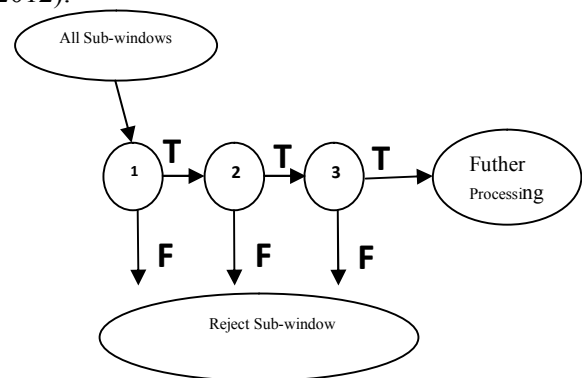
$$ii(x, y) = \sum_{x' \leq x, y' \leq y} i(x', y') \tag{2}$$

Guna mengetahui nilai *pixel* untuk beberapa segiempat yang lain, seperti segiempat D pada Gambar 2 (b), dapat dilakukan dengan cara menggabungkan jumlah *pixel* pada area segiempat A+B+C+D, dikurangi jumlah dalam segiempat A+B dan A+C, ditambah jumlah *pixel* di dalam A. Dengan, A+B+C+D adalah nilai dari *integral image* pada lokasi 4, A+B adalah nilai pada lokasi 2, A+C adalah nilai pada lokasi 3, dan A pada lokasi 1. Sehingga hasil dari D dapat dikomputasikan (Kusumanto, dkk, 2012).

$$D = (A + B + C + D) - (A + B) - (A + C) + A \tag{3}$$

**3. Cascade Classifier**

*Cascade classifier* seperti yang ditunjukkan pada Gambar 3 adalah sebuah rantai *stage classifier*, dimana setiap *stage classifier* digunakan untuk mendeteksi apakah didalam *image sub window* terdapat obyek yang diinginkan (*object of interest*). *Stage classifier* dibangun dengan menggunakan algoritma *adaptive-boost* (AdaBoost). Algoritma tersebut mengkombinasikan *performance* banyak *weak classifier* untuk menghasilkan *strong classifier*. *Weak classifier* dalam hal ini adalah nilai dari *haar-like feature*. Jenis AdaBoost yang digunakan adalah *Gentle AdaBoost* (Kusumanto, dkk, 2012).



**Gambar 3** Model *Classifier* Secara *Cascade*

**B. Deep Learning**

*Deep learning* adalah sebuah bidang keilmuan baru dalam bidang *machine learning*. *Deep learning* memiliki kemampuan yang sangat baik dalam visi komputer. Salah satunya adalah pada kasus klasifikasi objek pada citra. Dengan mengimplementasikan salah satu metode *machine learning* yang dapat digunakan untuk klasifikasi citra objek yaitu *Convolution Neural Network* (CNN). Metode ini juga memiliki modifikasi berupa *Deep Conolution Neural Network* yang merupakan awal mula dari *deep learning* (Azizah, dkk, 2018).

Arsitektur *deep learning* seperti pada Gambar 4 bisa dijelaskan tahapan proses yang nantinya akan diolah sedemikian rupa dengan bantuan *deep learning* (Asri, Firmansyah, 2018) yang terdiri dari :


**1. Data Storage**

*Data storage* merupakan penyimpanan seluruh pelatihan citra digital yang nantinya akan di olah *layer*.



## 2. Layer

Layer disini bertugas sebagai tempat proses pengolahan citra digital yang telah ada didalam data *storage* untuk dibandingkan sehingga mendapatkan kesimpulan apa yang terdapat dalam citra digital tersebut.



**Gambar 4** Arsitektur *Deep Learning*

Metode pendekatan *deep learning* mengklasifikasi data dalam dua sesi yaitu sesi *training* dan *testing*. Pada sesi *training* mempelajari ekstrasi fitur dari setiap data supaya bisa membedakan suatu label dengan label yang lain. Pada sesi *testing* data-data yang diuji dapat dianalisa dari hasil sesi *training* (Azizah, dkk, 2018).

*Convolutional Neural Network* (CNN) merupakan salah satu metode dalam *Deep Learning* yang dibuat untuk menutupi kelemahan dari metode sebelumnya. Terdapat beberapa kelemahan dalam metode sebelumnya, tetapi dengan model ini sejumlah parameter bebas dapat dikurangi dan deformasi gambar input seperti translasi, rotasi dan skala dapat ditangani (Lecun, dkk, 1998).


*Convolutional Neural Network* merupakan salah satu jenis *neural network* yang biasanya digunakan dalam pengolahan data *image*. Konvolusi atau biasa yang disebut dengan *convolution* adalah matriks yang memiliki fungsi melakukan *filter* pada gambar. *Convolutional Neural Network* memiliki beberapa *layer* yang difungsikan untuk melakukan *filter* pada setiap prosesnya. Prosesnya disebut dengan proses *training*. Pada proses *training* terdapat 3 tahapan seperti pada Gambar 5 diantaranya yaitu *Convolutional layer*, *Pooling layer*, dan *Fully connected layer* (Santoso dan Ariyanto, 2018).



**Gambar 5** Proses *Convolutional Neural Network*

### a. Convolutional Layer


Seluruh data yang menyentuh lapisan konvolusional akan mengalami proses konvolusi. Lapisan akan mengkonversi setiap *filter* ke seluruh bagian data masukan dan menghasilkan sebuah *activation map* atau *feature map* 2D. *Filter* yang terdapat pada *Convolutional Layer* seperti pada Gambar 6 memiliki panjang, tinggi (*pixels*) dan tebal sesuai dengan *channel* data masukan. Setiap *filter* akan mengalami pergeseran dan operasi "dot" antara data masukan dan nilai dari *filter*. Lapisan konvolusional secara signifikan mengalami kompleksitas model melalui optimalisasi outputnya. Hal ini dioptimalkan melalui tiga parameter, *depth*, *stride*, dan pengaturan *zero padding* (O'Shea dan Nash, 2015).



**Gambar 6** *Convolutional Layer*

### b. Pooling Layer


*Pooling layer* seperti pada Gambar 7 merupakan tahap setelah *convolutional layer*. *Pooling layer* terdiri dari sebuah *filter* dengan ukuran dan *stride* tertentu. Setiap pergeseran akan ditentukan oleh jumlah *stride* yang akan digeser pada seluruh *area feature map* atau *activation map*. Dalam penerapannya, *pooling layer* yang biasa digunakan adalah *max pooling* dan *average pooling*. Sebagai contoh, apabila digunakan *max pooling* 2x2 dengan *stride* 2, maka pada setiap pergeseran *filter*, nilai yang diambil adalah nilai yang terbesar pada area 2x2 tersebut, sedangkan *average pooling* akan mengambil nilai rata-rata (Santoso dan Ariyanto, 2018).



### Gambar 7 Pooling Layer

#### c. Fully Connected Layer

*Feature map* yang dihasilkan oleh tahap sebelumnya berbentuk multidimensional *array*. Sehingga, Sebelum masuk pada tahap *fully connected layer*, *feature map* tersebut akan melalui proses “*flatten*” atau *reshape*. Proses *flatten* menghasilkan sebuah vektor yang akan digunakan sebagai input dari *fully connected layer*. *Fully connected layer* seperti pada Gambar 8 memiliki beberapa *hidden layer*, *action function*, *output layer* dan *loss function* (Santoso dan Ariyanto, 2018).



Gambar 8 Fully Connected Layer

## 3. METODE PENELITIAN

### 3.1. Pengumpulan Dataset

Data yang diambil adalah video mahasiswa berdurasi lebih dari satu menit dengan jumlah mahasiswa sebanyak 100 mahasiswa. Hasil video mahasiswa yang telah diambil, kemudian akan dijadikan data gambar yang nantinya digunakan sebagai data *training* dan juga data *testing*. Data *training* terdiri dari 25 gambar wajah dari setiap mahasiswa sebanyak 100 mahasiswa, sehingga total dari keseluruhan data *training* yaitu 2500 gambar wajah mahasiswa. Sedangkan pada data *testing* terdiri dari 5 gambar wajah dari setiap mahasiswa sebanyak 100 mahasiswa, sehingga total dari keseluruhan untuk data *testing* yaitu 500 gambar wajah mahasiswa. Jadi total gambar yang akan digunakan pada penelitian ini sebanyak 3000 gambar wajah dari 100 mahasiswa Universitas Nurul Jadid. Hasil video berformat .mp4 dengan resolusi 1920 x 1080 *pixels* menggunakan kamera HP Samsung J7 2016. Pengambilan video dilakukan di lingkungan Universitas Nurul Jadid selama jam perkuliahan dengan jarak  $\pm 40$  sampai  $\pm 70$  cm dan posisi kamera tegak lurus dengan objek. Pengambilan data ini dilakukan pagi hari sampai dengan sore hari selama empat hari pada Maret 2019.

### 3.2. Pre-processing Tahap Satu

Pada tahap ini dilakukan pemotongan durasi video menjadi durasi 1 menit pada 100 video mahasiswa yang sudah diambil dengan menggunakan aplikasi Filmora versi 8.0.0. Setelah dilakukan pemotongan video, selanjutnya akan dilakukan *resize* video mahasiswa untuk memperkecil ukuran video dari **resolusi 1920 x 1080 *pixels* menjadi resolusi 640 x 480 *pixels*** dan menjadikan satu ukuran yang sama pada setiap video mahasiswa dengan ukuran  $\pm 11$  MB.

### 3.3. Implementasi Deteksi Wajah dengan Haar Cascade

Pada tahap ini sistem mendeteksi wajah dan *Crop* Wajah mahasiswa pada video dengan metode *haar cascade* menggunakan perintah koding *Python*.

### 3.4. Pre-processing Tahap Dua

Pada tahap ini dilakukan proses *resize image*, gambar wajah dari 100 mahasiswa dimana masing-masing mahasiswa terdiri dari 30 gambar, jadi total gambar yang akan di *resize* sebanyak 3000 gambar. Pada proses *resize image*, semua gambar disamakan resolusinya menjadi 100 x 100 *pixels* dengan ukuran 4.00 KB dan format .jpg. *Resize image* dilakukan secara *online* dengan aplikasi *Bulk Resize Photos*. Hasil *resize image* kemudian dikelompokkan menjadi dua kelas yaitu kelas data *training* dan kelas data *testing*.

### 3.5. Implementasi Pengenalan Wajah dengan Deep Learning

Data *training* gambar wajah mahasiswa yang sudah siap, selanjutnya dilakukan proses *training* (pelatihan) pada tahap implementasi pengenalan wajah dengan menggunakan metode *deep learning*. Proses *training* (pelatihan) data dilakukan pada perangkat prosesor Intel® Celeron(R) CPU N3050 @1.60GHz (2 CPUs), ~1.6Ghz dengan memori 2048 RAM. Sistem operasi yang digunakan Windows 10 Enterprise 2016 LTSC 64-bit (10.0, Build 14393). Proses *training* data ini menggunakan aplikasi *Python*. Gambar yang di *training* ada 100 kelas, setiap kelas berisi 25 gambar wajah mahasiswa. Total dari data wajah mahasiswa keseluruhan yang akan di *training* sebanyak 2500 gambar dari 100 mahasiswa. Proses *training* menggunakan salah satu metode *deep learning* yaitu *convolutional neural network* (CNN).

Hasil *training* tersebut digunakan sebagai data acuan pada saat proses uji coba.

### 3.6. Uji coba

Uji coba dilakukan pada perangkat prosesor Intel® Celeron(R) CPU N3050 @1.60GHz (2 CPUs), ~1.6Ghz dengan memori 2048 RAM. Sistem operasi yang digunakan Windows 10 Enterprise 2016 LTSB 64-bit (10.0, Build 14393). Pada tahap ini dilakukan uji coba pada metode *haar cascade* dan metode *deep learning*. Terdapat dua macam uji coba yang akan dilakukan yaitu sebagai berikut.

#### a) Uji Coba pada Gambar

Pada uji coba gambar yang dilakukan, terdapat 500 gambar *testing* dari 100 mahasiswa. Uji coba pada gambar mahasiswa dilakukan agar dapat mengetahui tingkat akurasi, data *testing* yang diuji dicocokkan dengan data *training* (pelatihan) yang telah dilatih dengan metode *deep learning* pada tahap sebelumnya. Uji coba pada gambar ini menggunakan *Python*. Berikut rumus untuk menghitung tingkat akurasi pada uji coba gambar.

$$Akurasi = \frac{\sum Data Benar}{\sum Data Uji} \times 100\% \quad (4)$$

Keterangan :

$\sum Data Benar$  = Banyak Data Benar

$\sum Data Uji$  = Banyak Data Uji

#### b) Uji Coba pada Video

Setelah uji coba pada gambar telah dilakukan, pada tahap selanjutnya yaitu melakukan uji coba yang kedua yaitu uji coba video. Uji coba yang kedua ini tujuannya agar dapat mengetahui metode *haar cascade* dan metode *deep learning* yang diterapkan berhasil atau tidak pada video.


## 4. HASIL DAN PEMBAHASAN

### 4.1. Uji Coba pada Gambar

Hasil dari uji coba pada gambar dengan *epochs* 50 dan *steps* 300 pada 500 gambar didapatkan tingkat akurasi 99,6% berhasil terdeteksi. Gambar wajah mahasiswa yang menjadi data *testing* dapat dikenali sesuai dengan data wajah mahasiswa yang telah dilakukan *training* sebelumnya, dimana pada gambar wajah mahasiswa yang dilakukan *training* seluruhnya terdapat 2500 gambar wajah mahasiswa dari 100 mahasiswa dengan berbagai macam ekspresi diantaranya ekspresi wajah datar, sedih, marah, cemberut, dan

sebagainya. Pada data *testing* terdapat 500 gambar wajah mahasiswa dari 100 mahasiswa dengan berbagai macam ekspresi juga. Pada data *testing* yang telah dilakukan uji coba terdapat 498 gambar wajah mahasiswa yang berhasil terdeteksi dengan benar dan terdapat 2 gambar wajah mahasiswa yang terdeteksi dengan salah. Gambar wajah mahasiswa yang tidak terdeteksi dengan benar tersebut yaitu berada pada nama folder 5 dengan nama file 5.jpg dan pada nama folder 46 dengan nama file 4.jpg. Gambar 9 merupakan data *testing* gambar wajah mahasiswa yang berhasil terdeteksi dengan benar dan yang tidak berhasil terdeteksi dengan benar.

Gambar 9 merupakan 2 folder dari 100 folder gambar wajah mahasiswa yang terdapat pada data *testing*, dimana masing-masing dari 2 folder tersebut didalamnya terdapat satu gambar wajah mahasiswa yang tidak berhasil terdeteksi dengan benar dari 500 gambar wajah mahasiswa yang dijadikan data *testing*. Gambar (a) dan (c) merupakan gambar wajah mahasiswa yang terdeteksi dengan benar. Gambar (b) tidak berhasil terdeteksi dengan benar saat wajah menghadap ke depan dan memejamkan mata. Gambar (d) tidak berhasil terdeteksi dengan benar saat wajah sedikit miring ke kanan dan tatapan mata tidak menatap ke kamera.




Gambar 9 Data Testing Gambar

### 4.2. Uji Coba Pada Video

Uji coba pada video *testing* untuk mendeteksi adanya wajah mahasiswa pada video dengan menggunakan metode *haar cascade* dapat dilakukan dengan baik. Semua wajah mahasiswa pada video yang dijadikan



video *testing* berhasil terdeteksi oleh metode *haar cascade*. Akan tetapi, metode *haar cascade* pada video *testing* tersebut juga mendeteksi yang bukan wajah. Hal ini dikarenakan objek apapun pada video yang bentuknya mirip seperti wajah manusia maka oleh metode *haar cascade* tersebut akan di deteksi adanya wajah. Gambar 10 pada gambar (a) dan gambar (b) merupakan contoh metode *haar cascade* juga mendeteksi yang bukan wajah.




**Gambar 10** Hasil Video *Testing* I

Ketika wajah sudah terdeteksi oleh metode *haar cascade*, maka metode *deep learning* mengidentifikasi wajah mahasiswa tersebut. Hasil identifikasi wajah pada video *testing* menggunakan *convolutional neural network (CNN)*. Dimana *CNN* tersebut terdiri dari 3 tahapan yaitu *convolutional layer*, *pooling layer*, dan *fully connected layer*. Dimana setiap *layer* di set dengan ukuran tertentu dan juga menggunakan *epochs* 50 dan *steps* 300 pada metode *deep learning* berhasil dilakukan secara baik dari 100 mahasiswa yang dijadikan data *training*. Akan tetapi ada beberapa hal sangat mempengaruhi metode *deep learning* tersebut untuk mengidentifikasi wajah mahasiswa pada video, antara lain tingkat cahaya dan komposisi warna pada video. Tingkat cahaya pada video mempengaruhi identifikasi wajah yang dilakukan oleh metode *deep learning*. Ketika tingkat cahaya tidak sesuai dengan tingkat cahaya pada gambar wajah data *training* mahasiswa maka identifikasi wajah mahasiswa pada video tidak berhasil terdeteksi dengan benar oleh metode *deep learning*.


Komposisi warna pada video juga mempengaruhi identifikasi wajah mahasiswa pada video yang dilakukan oleh metode *deep learning*. Jika warna kerudung mahasiswa tidak sesuai dengan warna kerudung yang digunakan pada data *training* maka wajah mahasiswa tersebut teridentifikasi dengan wajah mahasiswa lain yang sama dengan warna kerudung pada data *training* (tidak berhasil). Saat pengambilan video *testing* berbeda tempat dengan proses pengambilan data *training* otomatis *background* juga berbeda, maka metode *deep learning* tersebut

mengidentifikasi wajah mahasiswa yang sama dengan warna *background* mahasiswa pada data *training* (tidak berhasil).

Gambar 11 merupakan hasil dari video *testing*, gambar (a) wajah mahasiswa tidak berhasil teridentifikasi dengan benar pada video meskipun komposisi warnanya (warna kerudung) sama dengan komposisi warna pada data *training*, akan tetapi tingkat cahaya pada video *testing* tersebut tidak sesuai dengan tingkat cahaya pada data *training*, maka wajah mahasiswa pada gambar (a) diidentifikasi dengan mahasiswa yang tingkat cahayanya sama. Gambar (b) wajah mahasiswa tidak berhasil teridentifikasi dengan benar karena komposisi warnanya (warna kerudung) tidak sesuai dengan komposisi warna yang dijadikan data *training*, tingkat cahaya pada gambar (b) juga berbeda dengan tingkat cahaya pada data *training*, maka gambar (b) teridentifikasi dengan wajah mahasiswa dengan komposisi warna (warna kerudung) yang sama. Gambar (c) wajah mahasiswa berhasil terdeteksi dengan benar karena tingkat cahaya dan komposisi warnanya (warna kerudung) sama dengan data *training*. Gambar (d) wajah mahasiswa tidak berhasil teridentifikasi dengan benar oleh metode *deep learning* karena komposisi warna (warna kerudung) yang berbeda dengan komposisi warna pada data *training*, maka mahasiswa pada gambar (d) teridentifikasi dengan wajah mahasiswa yang komposisi warnanya (warna kerudung) sama. Gambar (e) wajah mahasiswa tersebut pada video berhasil teridentifikasi dengan benar karena tingkat cahaya pada video sama dengan tingkat cahaya pada data *training*, dan juga komposisi warnanya (warna kerudung) hampir sama dengan komposisi warna (warna kerudung) pada data *training*. Gambar (f) wajah mahasiswa pada video tidak berhasil teridentifikasi dengan benar karena *background* yang tidak sama dengan *background* pada data *training*, maka wajah mahasiswa pada gambar (f) teridentifikasi dengan wajah mahasiswa yang *background*-nya sama dengan wajah mahasiswa pada video.







**Gambar 11** Hasil Video Testing II

Data *training* gambar wajah mahasiswa yang digunakan pada penelitian ini masih sedikit yaitu masing-masing mahasiswa 25 gambar sedangkan jumlah mahasiswa yang dijadikan data *training* sebanyak 100 mahasiswa jadi total gambar yang digunakan hanya 2500 gambar wajah mahasiswa. Data *training* gambar wajah mahasiswa dimana setiap mahasiswa terdiri dari 25 gambar dan gambar wajah mahasiswa tersebut terdiri dari komposisi warna dan tingkat cahaya yang sama dengan waktu dan tempat yang sama pula sehingga sangat mempengaruhi proses identifikasi wajah mahasiswa yang dilakukan pada video. Wajah mahasiswa pada video *testing* yang digunakan terdiri dari komposisi warna, tingkat cahaya, waktu dan tempat yang berbeda dengan data *training*, sedangkan data *training* sebagai data acuan untuk mengidentifikasi wajah mahasiswa pada video *testing*. Data *training* terdiri dari 25 gambar wajah setiap mahasiswa dengan komposisi warna, tingkat cahaya, waktu dan tempat yang sama pula. Kelemahan dari metode *deep learning* yaitu memerlukan data *training* yang cukup banyak.

## 5. KESIMPULAN DAN SARAN

### 5.1. Kesimpulan

Setelah melakukan penelitian dan membahas hasil dari penelitian pengenalan wajah mahasiswa Universitas Nurul Jadid pada video menggunakan metode *Haar Cascade* dan *Deep Learning* secara tuntas, maka dapat disimpulkan sebagai berikut.

- Metode *haar cascade* dapat mendeteksi adanya wajah pada video secara baik. Metode *haar cascade* tersebut dapat mendeteksi semua wajah mahasiswa, akan tetapi metode *haar cascade* juga mendeteksi yang bukan wajah pada data *testing*.
- Pengenalan wajah mahasiswa menggunakan metode *haar cascade* dan *deep learning* pada gambar *testing* sebanyak 500 gambar dari 100 mahasiswa berhasil teridentifikasi secara benar dengan tingkat akurasi 99,6%. Hal ini terjadi karena data *training* dan data

*testing* diambil dalam waktu dan tempat yang sama.

- Metode *deep learning* dapat mengidentifikasi wajah secara baik pada video jika komposisi warna dan tingkat cahayanya sama dengan data *training*. Jika komposisi warna dan tingkat cahayanya tidak sesuai dengan data *training* maka metode *deep learning* tidak berhasil mengidentifikasi wajah mahasiswa pada video secara benar.

### 5.2. Saran

Adapun saran atau masukan untuk kedepannya pada penelitian ini adalah sebagai berikut.

- Pengenalan wajah pada video dengan menggunakan metode *haar cascade* dan *deep learning* dapat dikembangkan lebih lanjut oleh peneliti-peneliti selanjutnya agar mendapatkan hasil yang lebih baik seperti penggunaan metode pendeteksi wajah yang lebih baik dari metode *haar cascade*, wajah yang telah terdeteksi diharapkan dapat diisolasi agar mempermudah proses pengenalan wajah, mendapatkan data *training* yang cukup banyak, dan meneliti arsitektur lain pada metode *deep learning*.
- Pengenalan wajah pada video menggunakan metode *haar cascade* dan *deep learning* dapat dikembangkan lagi menjadi sebuah sistem perancangan untuk dapat menjadi sebuah aplikasi.

### DAFTAR PUSTAKA

- Mukaromah, I. F. (2018). *Face Recognition Mahasiswa Universitas Nurul Jadid (UNUJA) dengan Metode Eigenface*. Probolinggo: 2018.
- Kusumanto, R., Pambudi, W. S., & Tomponu, A. N. (2012). Aplikasi Sensor Vision untuk Deteksi MultiFace dan Menghitung Jumlah Orang. *Seminar Nasional Teknologi Informasi & Komunikasi Terapan 2012 (Semantik 2012)*, 8.
- Suharso, A. (2016). Pengenalan Wajah Menggunakan Metode Viola-Jones dan Eigenface Dengan Variasi Posisi Wajah Berbasis Webcam. *Jurnal Ilmu Komputer & Teknologi Informasi*, 12.
- Jefry Sunupurwa Asri, G. F. (2018). Implementasi objek detection dan tracking menggunakan *deep*

- learning untuk pengolahan citra digital. *Konferensi Nasional Sistem Informasi 2018*, 7.
- Syarif, M., & Wijianto. (2015). Deteksi kedipan mata dengan Haar Cascade Classifier dan Contour untuk Password Login Sistem. *Techno.COM, Vol. 14, No. 4, November 2015*, 8.
- Astini, N. (2018). Segmentasi Citra Parasit Malaria Plasmodium Vivax Dengan Menggunakan Metode Haar Cascade. *Prosiding Seminar Nasional Pendidikan Teknik Informatika*, 5.
- O'Shea, K., & Nash, R. (2015). An Introduction to Convolutional Neural Networks. *arXiv:1511.08458v2 [cs.NE] 2 Dec 2015*, 11.
- Marti, N. W. (2010). Pemanfaatan Gui dalam Pengembangan Perangkat Lunak Pengenalan Citra Wajah Manusia menggunakan Metode Eigenfaces. *Seminar Nasional Aplikasi Teknologi Informasi 2010 (SNATI 2010)*, 6.
- Lecun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-Based Learning Applied to Document Recognition. *Proc. Of The IEEE*, 46.
- Hardiyanto, D., & Sartika, D. A. (2018). Optimalisasi Metode Deteksi Wajah berbasis Pengolahan Citra untuk Aplikasi Identifikasi Wajah pada Presensi Digital. *Sistem Kendali-Tenaga-Elektronika-Telekomunikasi-Komputer*, 10.
- Azizah, L. M., Umayah, S. F., & Fajar, F. (2018). Deteksi Kecacatan Permukaan Buah Manggis Menggunakan Metode Deep Learning dengan Konvolusi Multilayer. *SEMESTA TEKNIKA*, 7.
- Santoso, A., & Gunawan, A. (2018). Implementasi Deep Learning Berbasis Keras Untuk Pengenalan Wajah. *Jurnal Emitor*, 7.
- Zufar, M., & Setiyono, B. (2016). Convolutional Neural Networks untuk Pengenalan Wajah Secara Real-Time. *Jurnal Sains dan Seni ITS*, 6.
- Al-Aidid, S., & Pamungkas, D. S. (2016). Sistem Pengenalan Wajah dengan Algoritma Haar Cascade dan Local Binary Pattern Histogram. *Jurnal Rekayasa Elektrika*, 8.
- Putro, M. D., Adji, T. B., & Winduratna, B. (2012). Sistem Deteksi Wajah dengan Menggunakan Metode Viola-Jones. *Seminar Nasional "Science, Engineering and Technology"*, 5.
- Wuryandari, M. D., & Afrianto, I. (2012). Perbandingan Metode Jaringan Syaraf Tiruan Backpropagation dan Learning Vector Quantization pada Pengenalan Wajah. *Jurnal Komputer dan Informatika (KOMPUTA)*, 7.
- Heranurweni, S. (2010). Pengenalan Wajah Menggunakan Learning Vector Quantization (LVQ). *Prosiding Seminar Nasional Sains dan Teknologi 2010*, 9.
- Hidayatno, A., Isnanto, R. R., & Kurniawan, D. (2006). Penentuan Wilayah Wajah Manusia Pada Citra Berwarna Berdasarkan Warna Kulit dengan Metode Template Matching. *Teknologi Elektro*, 8.