

# Klasifikasi Gender Berdasarkan Gambar Menggunakan Metode *Deep Learning* Pada MATLAB

Haenuki Sachi<sup>1</sup> Linda Wijayanti<sup>2\*</sup> Sandra Octaviani<sup>3</sup>

<sup>1,3</sup> Program Studi Teknik Elektro, Fakultas Teknik  
Universitas Katolik Indonesia Atma Jaya, Jakarta 12930, Indonesia  
<sup>2</sup> Program Studi Program profesi Insinyur, Fakultas Teknik  
Universitas Katolik Indonesia Atma Jaya, Jakarta 12930, Indonesia

## Article Info

Article history:

Received:  
10-12-2023

Accepted:  
20-12-2023

Keywords:  
Convolutional Neural  
Network, Deep  
Learning Toolbox,  
Training Algorithm  
Options

## Abstract

*In the present era, machine intelligence, also known as Artificial Intelligence (AI), is demanded not only to execute specific commands but also to recognize, analyze, or even make decisions, thereby providing desired outputs. By harnessing the power of AI, it is anticipated that desired outcomes will be more accurate and goal achievement will be optimized, minimizing losses. With the capabilities of AI in mind, a research study has been conducted on AI's ability to analyze and make decisions based on specific data. In this study, data in the form of images of men and women were utilized. The objective of this research is to analyze the ability of AI, particularly in gender classification. The method employed in designing this system is Deep Learning, with GoogLeNet as the Convolutional Neural Network utilized. In testing, the data accuracy ranged from 61.8% to 100% for the system without training algorithm options and from 97.5% to 100% for the system with training algorithm options. Testing was also carried out on a smaller set of training data and grayscale images, yielding lower accuracy ranges. From this research, it can be concluded that the quantity of training data, image preprocessing, and training algorithm options are crucial indicators for enhancing prediction accuracy.*

## Info Artikel

Histori Artikel:

Diterima:  
10-12-2023

Disetujui:  
20-12-2023

Kata Kunci:  
Convolutional Neural  
Network, Deep  
Learning Toolbox,  
Training Algorithm  
Options

## Abstrak

*Pada masa ini, kecerdasan mesin yang disebut sebagai Artificial Intelligence (AI) dituntut untuk tidak hanya melakukan perintah tertentu, tetapi juga mampu untuk mengenal, menganalisis, atau bahkan mengambil keputusan sehingga mampu memberikan keluaran yang diinginkan. Dengan menggunakan AI, diharapkan hasil yang diinginkan menjadi lebih akurat dan mampu mencapai tujuan dengan meminimalkan kerugian. Berlatar dari kemampuan AI tersebut, maka dilakukannya suatu penelitian mengenai kemampuan AI yang dapat menganalisis dan mengambil keputusan berdasarkan data-data tertentu. Pada penelitian ini, digunakan data berupa gambar pria dan wanita. Tujuan dari penelitian ini ialah menganalisis kemampuan AI khususnya dalam hal mengelompokkan gender. Metode yang digunakan adalah Deep Learning dengan GoogLeNet sebagai Convolutional Neural Network yang digunakan. Untuk hasil pengujian, akurasi mulai dari 61,8-100% untuk sistem tanpa training algorithm options dan 97,5-100% untuk sistem dengan training algorithm options. Pengujian juga dilakukan terhadap data training yang lebih sedikit dan juga gambar abu-abu dengan hasil rentang akurasi yang lebih rendah. Dari penelitian ini, dapat ditarik kesimpulan bahwa jumlah data training, preprocessing image, dan training algorithm options merupakan indikator yang penting untuk meningkatkan keakuratan prediksi.*

## 1. PENDAHULUAN

AI (*Artificial Intelligence*) merupakan bentuk kecerdasan dari mesin yang mampu mengenal, menganalisis, dan bahkan mengambil keputusan sehingga langsung memberikan keluaran. AI sendiri

\*Corresponding author: Linda Wijayanti  
Email address: [linda.wijayanti@atmajaya.ac.id](mailto:linda.wijayanti@atmajaya.ac.id)

tidak lepas dari kehidupan manusia modern karena kemampuannya yang relatif cepat untuk penyelesaian kasus-kasus tertentu dibanding manusia. Dalam melakukan perancangan AI, terdapat beberapa metode seperti *deep learning*, *machine learning*, dan *reinforcement learning*.

Penelitian ini berfokus pada metode *deep learning*. *Deep learning* sendiri merupakan pembelajaran untuk mesin agar mampu mengenali sesuatu dengan cara pikir yang mirip dengan sistem kerja korteks pada otak manusia. Hal itu dikarenakan proses pemecahan suatu kasusnya menggunakan sistem yang identik, mulai dari kumpulan gambar atau data dari sebuah input yang diolah dengan beberapa jenis dan menghasilkan keluaran langsung berupa jawaban utuh dari sistem [1].

Berdasarkan penjelasan di atas, teknologi AI sangat berkembang pesat di era sekarang. Selain itu, penerapan *deep learning* juga mampu membantu manusia dalam menyelesaikan beberapa masalah seperti masalah klasifikasi. Berangkat dari penjelasan tersebut, maka disusunlah sebuah penelitian yang berjudul “Klasifikasi Jenis Kelamin Berdasarkan Gambar Menggunakan Metode Deep Learning pada Matlab”. Hasil analisis nantinya berupa tingkat keakuratan prediksi di berbagai macam kondisi (termasuk perubahan berbagai macam parameter *training algorithm options*), sehingga untuk kedepannya peneliti lain mampu meningkatkan akurasi dari penelitian mereka bila menggunakan CNN (*Convolutional Neural Network*) berupa GoogLeNet.

## 2. TEORI DASAR

### 2.1 Artificial Intelligence

AI merupakan kecerdasan yang ditambahkan kepada suatu sistem yang bisa diatur dalam konteks ilmiah. Menurut Andreas Kaplan dan Michael Haenlein, AI merupakan kemampuan sistem untuk menafsirkan data eksternal dengan benar, untuk belajar dari data tersebut, dan menggunakan pembelajaran tersebut guna mencapai tujuan dan tugas tertentu melalui adaptasi yang fleksibel [2]. Secara umum AI merupakan usaha yang digunakan untuk membuat sebuah mesin yang menyerupai kecerdasan manusia. Beberapa bidang yang memanfaatkan dan mengembangkan AI antara lain robotika, *fuzzy logic*, sistem pakar, permainan komputer/*games*, dan jaringan saraf tiruan.

Dalam bidang komputer, AI dapat berperan sebagai adaptasi kecerdasan dalam sebuah mesin, berhubungan dengan perilaku, dan pembelajaran. Beberapa hal yang dapat dilakukan dengan menggunakan AI adalah pengendalian, perencanaan dan penjadwalan, kemampuan untuk menjawab diagnosa dan pertanyaan, pengenalan tulisan tangan, suara serta wajah. AI dapat terbagi menjadi 2 pemahaman, yaitu AI konvensional yang melibatkan beberapa metode yang sekarang diklasifikasikan sebagai pembelajaran mesin (dengan formalisme dan analisis statistik) dan AI kecerdasan komputasional yaitu pengembangan atau pembelajaran iteratif misalnya penalaran parameter seperti dalam sistem koneksi.


Pada era industri saat ini, AI sangat berkembang dalam bidang otomatisasi dengan pengimplementasiannya pada robotika. AI yang sangat kompleks berperan penting untuk mengurangi risiko kerugian dalam produksi serta untuk membuat suatu sistem yang menghasilkan produk yang akurat dan presisi dengan biaya produksi yang bisa ditekan pula. Selain itu, untuk cakupan yang lebih umum adalah dalam menerapkan proyek IoT dan otomasi, mesin harus memiliki kecerdasan yang cukup tinggi [3].

Untuk membangun sebuah *Artificial Intelligence* maka dapat menggunakan *deep learning*, *machine learning*, dan *reinforcement learning* bila menggunakan Matlab. Secara umum, inti dari AI adalah *deep learning* sebagai *Neural Network* untuk seluruh proses, kemudian disempurnakan oleh algoritma *machine learning* untuk membuat mesin dapat mempelajari berbagai kasus sehingga mendapatkan hasil output yang akurat.

### 2.2 Deep Learning

*Deep learning* adalah salah satu percabangan dari bidang *machine learning* dengan pengembangan ide yang berasal dari korteks manusia, dengan mengimplementasikan *neural network* buatan yang memiliki banyak layer tersembunyi [1]. Dalam beberapa tahun belakangan ini, *deep learning* telah banyak diaplikasikan dalam berbagai hal, seperti misalnya fitur *facelock* pada *smartphone*, imigrasi, dan juga media sosial seperti contohnya (*face tagging*).

Proses *face tagging* memuat tahap deteksi (*detection*) dan tahap klasifikasi (*classification*). Prinsip sederhana sistem pengenalan wajah yaitu membandingkan satu citra wajah masukan dengan citra wajah yang terdapat di *database*, kemudian menghasilkan pendekatan dan kecocokan data dengan citra wajah yang ada [1]. Seperti yang telah diketahui sebelumnya, *deep learning* menggunakan *Artificial Neural Network* (ANN). Salah satu jenis neural network yang sering digunakan untuk pengolahan citra yaitu *Convolutional Neural Network* (CNN) [4]. Proses dari *Convolutional Neural Network* (CNN) dapat dilihat pada Gambar 1.



Gambar 1. Proses CNN

Pada CNN, terdapat beberapa *layer* yang digunakan dalam proses filterisasi terhadap sampel gambar. Proses ini kemudian dikenal sebagai *training*/latihan. Pada proses *training*, terdapat tiga tahapan *layer* utama yaitu *convolutional layer*, *pooling layer*, dan *fully connected layer*. *Convolutional layer* berfungsi untuk melakukan konvolusi, melakukan konversi tiap filter ke data input, dan membuat *feature map* 2D (*activation map*). Tahap selanjutnya ialah *pooling layer*. *Pooling layer* terdiri atas filter dan *stride* dengan ukuran tertentu, yang nantinya akan menentukan pergeseran pada *activation map*. Lapisan selanjutnya ialah *fully connected layer* yang memuat *output layer* dan *loss function*, *hidden layer*, serta *action function* [1].

### 2.3 Matlab

Matlab adalah kependekan dari Matrix Laboratory, yang merupakan *software* pemrograman tingkat tinggi yang dikembangkan oleh Mathworks dengan basis dasar matriks. Dalam pembentukan jaringan saraf tiruan untuk *deep learning*, Matlab merupakan aplikasi yang dipakai untuk memperoleh kesesuaian data antara data gambar masukan (*input*) dengan data keluaran (*output*) setelah dilakukannya beberapa pengujian (*training*) [5]. Pada Matlab, terdapat *toolbox Neural Network* yang mempermudah dalam menguji dan mencoba menjalankan fungsi. Salah satu CNN yang dapat digunakan pada matlab yaitu GoogLeNet. Pada umumnya, dilakukan proses *transfer learning* terlebih dahulu sebelum menggunakan CNN ini. Selain itu, Matlab juga bisa digunakan untuk mengolah citra, seperti perubahan ukuran atau konversi ke *grayscale*, *negative*, dan *monochrome*.

### 2.4 Google Net

GoogLeNet merupakan suatu jaringan konvolusional terdiri atas 22 lapisan yang arsitekturnya telah disajikan sedemikian rupa untuk pengenalan visual skala besar ImageNet pada tahun 2014 [6]. Pada GoogLeNet, dilakukan proses yang mirip dengan *deep learning* yaitu CNN. GoogLeNet memuat pembaruan dalam hal pengenalan suatu modul yang kini disebut *inception*. Prinsip dari *inception* adalah menjalankan beberapa operasi seperti *pooling* dan *convolution* dengan beberapa ukuran filter secara paralel sehingga tidak terjadi *trade-off*. Arsitektur GoogLeNet menggunakan CNN yang terinspirasi dari LeNet, tetapi sedikit berbeda karena menerapkan elemen *inception module*. Modul ini didasarkan pada beberapa konvolusi yang sangat kecil untuk mengurangi jumlah parameter secara drastis.

### 2.5 Dataset

*Dataset* adalah suatu kumpulan data yang berasal dari informasi yang sudah ada dan dikelola menjadi sebuah informasi untuk melakukan teknik dari ilmu *data mining*. Terdapat 2 jenis *dataset* yaitu *private* dan *public*. *Private dataset* adalah *dataset* yang kita ambil dari objek penelitian yang kita pakai. Sedangkan *public dataset* merupakan kumpulan dari data-data yang diambil dari penelitian publik yang telah disepakati dan disahkan secara umum. Karakteristik dataset adalah *dimensionality*, *sparsity*, dan *resolution*. Sementara tipe *dataset* antara lain *record data*, matriks, dokumen, transaksi, grafik, dan data terurut.

Fungsi dari *dataset* adalah menguji metode yang dikembangkan oleh peneliti dengan *public dataset*, sehingga penelitian tersebut dapat bersifat *comparable*, *repeatable*, dan *verifiable* terutama pada bidang ilmu *data mining*. *Data mining* adalah proses mengekstraksi dan mengidentifikasi pengetahuan yang didapatkan dari sekumpulan data yang cukup besar. Salah satu teknik *data mining* adalah klasifikasi yang digunakan untuk memprediksi kelas pada suatu label tertentu [7].

## 2.6 Kaggle

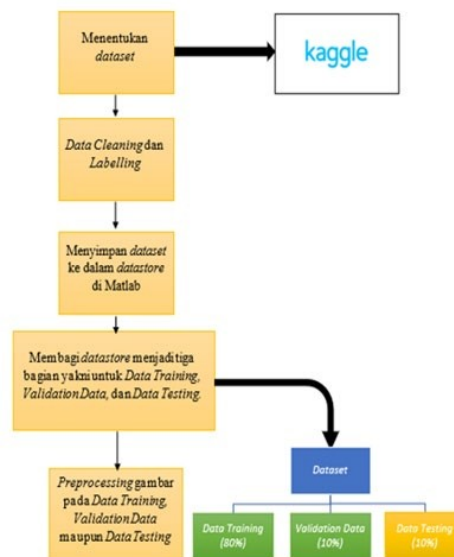
Kaggle merupakan sebuah *website* yang memudahkan dalam melakukan pencarian data dalam perancangan AI. Dalam Kaggle, terdapat banyak kumpulan data yang dapat digunakan sebagai *data training* dan *data testing* dari *pretrained network* yang telah dimodifikasi. Data-data yang terdapat pada Kaggle berupa *dataset*, *coding*, contoh proyek, dan juga *training*. Pada *website* Kaggle, kumpulan data yang dapat digunakan untuk diolah bisa berupa berbagai macam bentuk seperti gambar, grafik, sampai data angka. Perlu diketahui pula bahwa semakin banyak data yang diinput ke sistem untuk dilatih, maka semakin besar peluang suatu sistem menjadi akurat dalam menghasilkan prediksi *output*. Data yang terdapat pada Kaggle sangatlah beraneka ragam, mulai dari data alat hingga data percobaan tentang penyakit organ seperti jantung. Pada proyek ini, *dataset* yang akan digunakan dari Kaggle berupa *dataset* kategori *gender recognition* yang terdiri dari berbagai macam gambar pria dan wanita. Gambar-gambar ini digunakan untuk *training* sistem agar mampu mengidentifikasi jenis kelamin dari input gambar yang diberikan. *Dataset* yang terdapat dalam Kaggle berupa data mentah, sehingga perludanya penyesuaian ukuran dari gambar pada *dataset* itu terlebih dahulu.

## 3. PERANCANGAN SISTEM

Perancangan sistem terbagi menjadi 2 fase, yang pertama yaitu fase pengolahan *dataset* dan yang kedua yaitu modifikasi *pretrained network* GoogLeNet (*Transfer Learning*), *training*, serta *testing*.

### 3.1 Fase Pertama

Fase pengolahan dataset ditunjukkan pada Gambar 2. Pada fase ini, mula-mula dilakukan penentuan dataset dari website Kaggle yang ditunjukkan Gambar 3. Dalam hal ini, dataset yang ditentukan yaitu *Men/Women Classification* dengan jumlah gambar pria yang mencapai 1414 buah dan gambar wanita sebanyak 1940 buah. (<https://www.kaggle.com/playlist/menwomen-classification>).



Gambar 2 Fase pertama

Proses selanjutnya yang dilakukan adalah *data cleaning* dan *labelling*. Dari masing-masing 1414 gambar pria dan 1940 gambar wanita, akan difilter/disortir kembali untuk menghilangkan beberapa

gambar yang tidak sesuai. Kriteria- kriteria gambar yang tidak sesuai antara lain: gambar kartun, gambar yang terpotong, gambar yang buram dan *file* gambar yang *corrupt*.




Gambar 3. Kaggle

Setelah mensortir beberapa gambar, selanjutnya diperoleh masing-masing 100 gambar pria dan wanita untuk kemudian dilakukan proses *data labelling*. *Data labelling* yaitu mengelompokkan setiap gambar sesuai kategorinya dan memberi nama pada *file* gambar (Misalnya "Man (1), Man (2), dan seterusnya hingga Man (100)"). *Labelling* gambar pria dan wanita ditunjukkan pada Gambar 4 dan Gambar 5.



Gambar 4 *Labelling* gambar pria



Gambar 5 *Labelling* gambar wanita

Gambar-gambar yang telah melalui proses data *cleaning* dan data *labeling* selanjutnya akan diimpor ke dalam program Matlab. Penyimpanan gambar- gambar tersebut pada Matlab dikenal dengan sebutan *datastore*. *Datastore* tersebut kemudian dibagi menjadi *data training* (80%), *validation data* (10%), dan *data testing* (10%). Tahap berikutnya yang harus dilakukan setelah membagi *datastore* ialah *preprocessing image* pada masing- masing *data training*, *validation data*, dan *data testing*. *Preprocessing image* menggunakan perintah *augmented Image Datastore* pada Matlab.

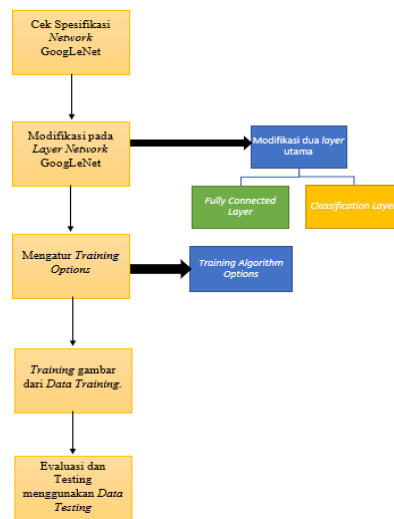
Tahap ini mengubah seluruh resolusi gambar menjadi 224 x 224 agar mampu untuk diinput ke *pretrained network* GoogLeNet tersebut. Perlu diingat pula bahwa setiap *pretrained network* atau CNN memiliki resolusi input yang berbeda-beda. Apabila terdapat gambar *gray*, gambar tersebut harus diubah ke dalam bentuk RGB pada Matlab dengan menggunakan perintah "gray2rgb". Alternatif lainnya apabila tidak ingin melakukan *preprocessing image* ialah dengan menggunakan data berupa gambar yang telah RGB dan berukuran 224x224 pixel.

### 3.2 Fase Kedua

Proses yang terjadi pada fase kedua ditunjukkan Gambar 6. Fase kedua diawali dengan pemeriksaan terhadap *network* GoogLeNet yang akan digunakan.

Analisis dilanjutkan untuk melihat *layer-layer* yang terdapat pada *network*. *Layer* pertama dari GoogLeNet dinamakan *image input*.

*Convolutional Neural Network* atau CNN yang digunakan juga harus dilakukan *transfer learning*. Secara default, GoogLeNet terdiri atas 1000 *fully connected layer* (*layer* 142). Oleh sebab itu, perlu dibuat *fully connected layer* yang baru untuk 2 kategori (*Men* dan *Women*). *Classification output* pada *layer* 144 juga harus diubah, seiring adanya perubahan pada *fully connected layer*. Pada dasarnya, masukan dan keluaran masing-masing *layer* inibergantung seberapa banyak jumlah kategori yang akan dikelompokkan oleh GoogLeNet.



Gambar 6. Fase kedua

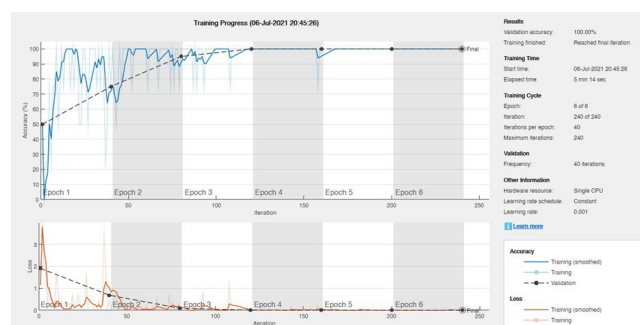
Data dan CNN yang mengalami *transfer learning* telah siap untuk melakukan *training*. Akan tetapi, pengaturan *training* pada *dataset* yang dilakukan oleh CNN masih harus dikonfigurasi. Dalam hal ini, dilakukan pengaturan terhadap *training algorithm options* yang terdiri atas *initial learn rate*, *max epochs*, *verbose*, dan *mini batch size*. Tujuan dilakukan *training algorithm options* ini ialah untuk menghindari keadaan *overfitting* (keadaan di mana tingkat akurasi prediksi semakin rendah seiring berjalannya proses *training*). Langkah terakhir yang dilakukan yaitu proses *testing* dan evaluasi.

*Testing* dilakukan dengan memasukkan *datastore data testing* ke dalam *pretrained network*. Selanjutnya akan dibandingkan antara hasil prediksi dengan hasil yang sebenarnya untuk mengetahui nilai keakuratan prediksi yang dilakukan oleh *pretrained network* tersebut.

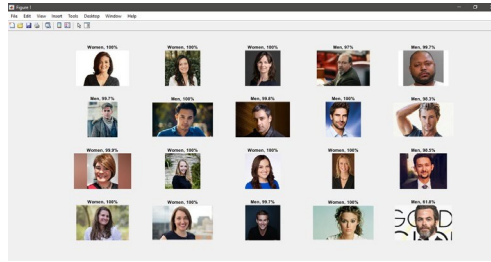
## 4. HASIL DAN PEMBAHASAN

### 4.1 Parameter Training Option

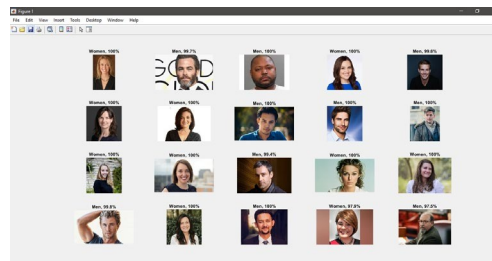
Hasil *Testing* dilakukan dengan cara mengambil 20 sampel gambar dari *data testing*. Hasil akurasi prediksi akan ditampilkan pada bagian atas gambar. *Testing* sendiri dilakukan pada *training* dengan *training algorithm options* dan *training* tanpa *training algorithm options*. Gambar 7 menunjukkan proses *training dataset*. Gambar 8 dan 9 menunjukkan hasil testing tanpa dan dengan konfigurasi *training algorithm option*.



Gambar 7 Proses training dataset



Gambar 8 Hasil testing tanpa konfigurasi *training algorithm options*




Gambar 9 Hasil testing dengan konfigurasi *training algorithm options*

Parameter-parameter *training options*:

1. *Max epochs* = 6
2. *Verbose* = true
3. *Mini batch size* = 4
4. *Initial learn rate* = 0.001


Dari beberapa hasil *testing*, dapat dilihat bahwa pengaturan *training algorithm options* membuat akurasi prediksi pada gambar semakin tinggi. Selain itu, proses *training* memakan waktu yang cukup lama karena *data training* yang cenderung banyak dan hanya menggunakan *hardware single CPU*. Waktu *training* dapat lebih dipersingkat apabila terdapat GPU yang memadai. Sementara itu, parameter-parameter di atas ditentukan dengan caramenggunakan metode *trial and error* serta *testing* dilakukan dengan 20 sampel gambar yang berbeda. Gambar 10 sampai Gambar 12 memperlihatkan hasil pengujian untuk *learn rate* 0,1 sedangkan Gambar 13 sampai dengan Gambar 15 memperlihatkan hasil pengujian dengan *learn rate* 0,000001.




Gambar 10 Proses *training dataset* (*initial learn rate* = 0.1)

Epoch	Loss	Train Accuracy	Validation Accuracy	Train Loss	Validation Loss	Train Accuracy	Validation Accuracy	Train Loss	Validation Loss
1	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000
2	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000
3	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000
4	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000
5	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000
6	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000
7	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000
8	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000
9	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000
10	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000

Gambar 11 *Verbose true* (*initial learn rate* = 0.1)



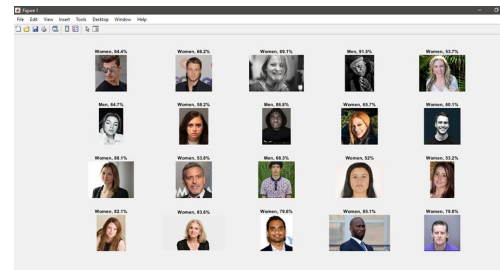
Gambar 12 Hasil *training* (*initial learn rate* = 0.1)



Gambar 13 Proses *training dataset* (*initial learn rate* = 0,000001)

Epoch	Iteration	Time Elapsed (hh:mm:ss)	Mini-batch Accuracy	Validation Accuracy	Mini-batch Loss	Validation Loss	Base Learning Rate
1	1	00:00:08	25.00%	25.00%	2.1859	1.4312	1.0000e-04
1	80	00:01:48	50.00%	25.00%	0.8066	1.3877	1.0000e-04
2	80	00:01:59	25.00%	25.00%	1.7404	1.0000e-04	1.0000e-04
2	160	00:02:12	50.00%	25.00%	0.7472	1.3385	1.0000e-04
3	160	00:02:12	50.00%	25.00%	1.1719	1.0000e-04	1.0000e-04
3	240	00:02:19	50.00%	25.00%	1.0275	1.2818	1.0000e-04
4	180	00:02:47	50.00%	25.00%	1.0399	1.0000e-04	1.0000e-04
4	240	00:02:59	75.00%	25.00%	0.9723	1.2467	1.0000e-04
5	200	00:03:43	50.00%	25.00%	0.4951	1.2114	1.0000e-04
6	240	00:04:29	25.00%	25.00%	1.2809	1.1749	1.0000e-04

Gambar 14 *Verbose true* (*initial learn rate* = 0.000001)



Gambar 15 Hasil *training* (*initiallearnrate* = 0.000001)

Analisis hasil pengujian:

1. Saat *initial learn rate* bernilai 0.1, *Mini- batch Accuracy* semakin kecil dan *Mini- batch Loss* tidak terdefinisi (NaN). Selain itu, tidak ada hasil prediksi pada output.
2. Hasil dengan *initial learn rate* 0.001 memperoleh hasil yang terbaik di antara ketiga parameter lainnya. *Mini- batch Accuracy* cenderung meningkat dan *Mini- batch Loss* menurun seiring berjalannya *training*. Hasil prediksi cenderung akurat dan persentasenya sekitar 97,5% hingga 100%.
3. Ketika *initial learn rate* bernilai 0.000001, maka model cenderung mengalami *overfitting*. *Mini- batch Accuracy* semakin kecil dan *Mini- batch-Loss* semakin besar seiring berjalannya *training*. *Output* menghasilkan prediksi kategori jenis kelamin yang tidak akurat serta persentase yang rendah.

Tabel 1. Perbandingan Hasil

Nilai <i>InitialLearn Rate</i>	Hasil Akurasi	Hasil Prediksi
0.1	Error/tidak ada prediksi	Tidak ada prediksi
0.001	97,5% - 100%	PrediksiAkurat
0.000001	52% - 91.5%	Prediksi banyak yang salah

Dari perbandingan ketiga nilai *initial learn rate* tersebut, dapat dilihat bahwa *initial learn rate* yang terlalubesar cenderung berpotensi menghasilkan *error* berupa tidak adanya hasil/prediksi. Sementara itu,



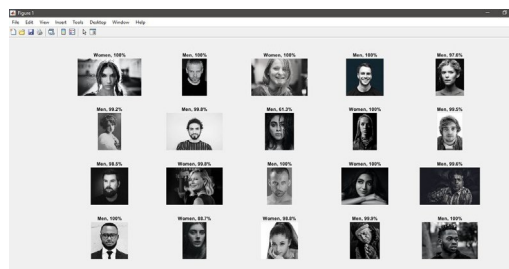
*initial learn rate* yang terlalu kecil justru membuat model berpeluang mengalami *overfitting* sehingga *training* yang berkelanjutan justru mengurangi kemampuan prediksi. Oleh karena itu, nilai *initial learn rate* harus disesuaikan (tidak terlalu besar dan tidak terlalu kecil).

Untuk parameter *verbose* sendiri adalah parameter yang digunakan untuk memunculkan keterangan *training* (*Mini-Batch Accuracy*, *Mini-Batch Loss*, *Epochs*, *Iteration*, dan lain-lain). Sementara untuk *max epochs* dan *mini batch size*, kedua parameter tersebut harus disesuaikan agar proses *training* tidak memakan *resources* dan waktu yang relatif lama. *Epoch* yang terlalu besar dan *mini batch size* yang terlalu kecil menghasilkan waktu *training* yang sangat lama serta relatif boros terhadap *resources*.

Selain menganalisis pengaruh *training algorithm options* dan parameternya, analisis juga dilakukan terhadap pengaruh gambar abu-abu terhadap keakuratan prediksi model. Percobaan selanjutnya yaitu menyisipkan beberapa gambar abu-abu ke dalam *training*. Penelitian juga dilakukan untuk melihat keakuratan/kemampuan dari CNNGoogLeNet dalam memprediksi gambar abu-abu.

#### 4.2 Uji Coba Gambar Grayscale

Uji coba dilakukan dengan menggunakan masing-masing 20 gambar pria dan wanita. Gambar-gambar tersebut akan digunakan sebagai *data testing* untuk melihat kemampuan memprediksi oleh model apabila gambarnya berwarna abu-abu. Model tersebut sebelumnya dilatih menggunakan gambar-gambar RGB. Hasil prediksi dari model tersebut ditunjukkan pada Gambar 16.




Gambar 16 Hasil prediksi model


Tingkat akurasi yang dihasilkan ketika *testing* dilakukan pada model dengan gambar berwarna abu-abu cenderung rendah dan bahkan persentase prediksinya ada yang hanya 61,3 %. Selain itu, terdapat pula kesalahan prediksi oleh model. Hal itu menunjukkan bahwa model yang dirancang menghasilkan persentase prediksi yang rendah dan kurang tepat apabila diuji coba pada gambar abu-abu (*grayscale*).

#### 4.3 Pengaruh Jumlah Data Training

Percobaan selanjutnya yang dilakukan adalah percobaan terhadap pengaruh jumlah *data training* terhadap keakuratan yang dihasilkan oleh model. Parameter yang digunakan bernilai sama dengan parameter pada percobaan dengan *training options*, hanya saja kali ini hanya akan ada 20 gambar pria dan 20 gambar wanita sebagai *dataset*. Gambar 17 dan 18 memperlihatkan proses *training* dan hasil prediksi yang dilakukan oleh model.



Gambar 17 Proses *training*



Gambar 18 Hasil prediksi model dengan *data training* yang lebih sedikit

Hasil yang diperoleh menunjukkan bahwa semakin banyak *data training*, maka waktu yang dibutuhkan untuk *training* model semakin lama. Sebaliknya semakin sedikit *data training* maka waktu training cenderung cepat, namun cenderung juga lebih tidak akurat.

## 5. KESIMPULAN

Dari percobaan yang dilakukan, dapat ditarik kesimpulan:

Lingkup akurasi prediksi suatu model (GoogLeNet) dipengaruhi oleh:

- a. jumlah *data training*, *preprocessing images*, dan *training algorithm options*.
  - b. pemilihan gambar baik untuk *data training* maupun untuk *data testing* dan *validation data*.
2. Nilai *initial learn rate* yang terlalu besar akan menyebabkan *error* pada prediksi, sedangkan bila terlalu kecil akan menyebabkan model mengalami *overfitting*.
  3. *Epoch* yang terlalu besar dan *mini batch size* yang terlalu kecil akan menyebabkan waktu proses *training* berlangsung lama dan membutuhkan *resources* yang besar.

## DAFTAR PUSTAKA

- [1] A. Santoso and G. Ariyanto, "Implementasi Deep Learning Berbasis Keras untuk Pengenalan Wajah," *Emitor: Jurnal Teknik Elektro*, vol. 18, no. 1, pp. 15-21, 2018.
- [2] A. Kaplan and . M. Haenlein, "Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence," *Business Horizons*, vol. 62, no. 1, pp. 15-25, 2019.
- [3] R. Yogaswara, "Artificial Intelligence Sebagai Penggerak Industri 4.0 Dan Tantangannya Bagi Sektor Pemerintah Dan Swasta," *Masyarakat Telematika Dan Informasi : Jurnal Penelitian Teknologi Informasi Dan Komunikasi*, vol. 10, no. 1, p. 68, 2019.
- [4] A. e. a. Peryanto, "Rancang Bangun Klasifikasi Citra Dengan Teknologi Deep Learning Berbasis Metode Convolutional Neural Network," *Jurnal Ilmiah Teknik Informatika*, vol. 8, no. 2, p. 138, 2020.
- [5] A. Sadli, "Simulasi Pengenalan Karakter Menggunakan Neural Network pada Matlab," *Jurnal Sistem Informasi dan Teknologi Informasi*, vol. 7, no. 1, pp. 89-97, 2018.
- [6] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke and A. Rabinovich, "Going Deeper with Convolutions," *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2015.
- [7] N. Sagala and H. Tampubolon, "Komparasi Kinerja Algoritma Data Mining Pada Dataset Konsumsi Alkohol Siswa," *Khazanah Informatika: Jurnal Ilmu Komputer Dan Informatika*, vol. 4, no. 2, p. 98, 2018.