



Hak cipta dan penggunaan kembali:

Lisensi ini mengizinkan setiap orang untuk menggubah, memperbaiki, dan membuat ciptaan turunan bukan untuk kepentingan komersial, selama anda mencantumkan nama penulis dan melisensikan ciptaan turunan dengan syarat yang serupa dengan ciptaan asli.

Copyright and reuse:

This license lets you remix, tweak, and build upon work non-commercially, as long as you credit the origin creator and license it on your new creations under the identical terms.

BAB II

TINJAUAN PUSTAKA

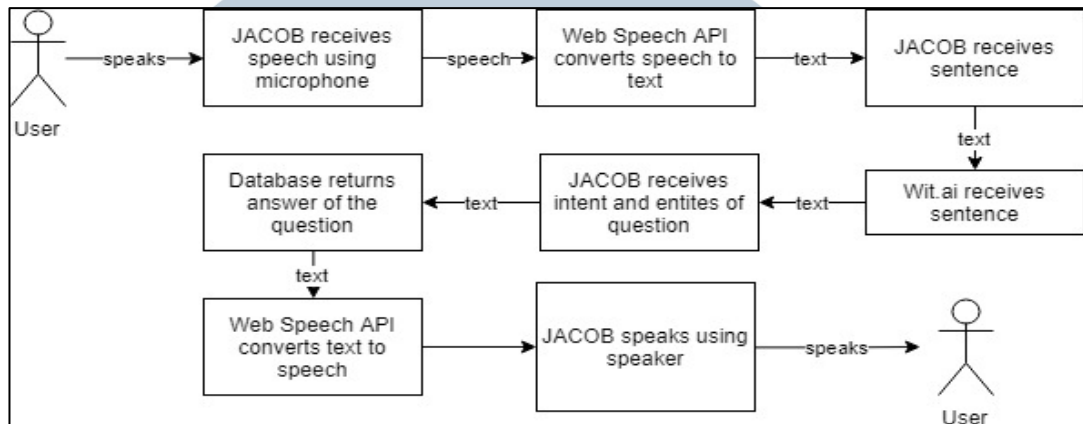
2.1. Voice Chatbot Jacob

Jacob adalah sebuah aplikasi *chatbot* berbasis suara yang digunakan untuk menyediakan informasi tentang program studi Informatika Dual Degree Universitas Multimedia Nusantara (Wijaya, 2019). Jacob dikembangkan menggunakan *platform* Wit.AI dan penyimpanan data menggunakan basis data MySQL berbasis web (Wijaya, 2019).

Wit.AI adalah *cloud platform* milik dan dikembangkan oleh Facebook. Perbedaan Wit.AI dengan *natural language understanding* (NLU) adalah Wit.AI berfokus memahami makna dari satu kalimat (Canonic dan Russis, 2018). Wit.ai menggunakan integrasi *webhook* dimana informasi dikirimkan melalui *web service*. Kemudian, Wit.AI memberikan jawaban berupa tujuan dan entitas atau pengguna dapat menentukan entitas sendiri. Dalam penentuan tujuan dan *entities*, Wit.AI menggunakan dan mempelajari dari contoh kalimat serupa yang pernah digunakan sebelumnya (Rahman dkk., 2017).

Jacob bekerja dengan menerima masukan suara. Suara kemudian akan diubah menjadi teks menggunakan *library* Web Speech API, yaitu *Speech Recognition*. Teks yang telah diubah kemudian akan dikirimkan kepada platform Wit.AI dan balasan yang diterima berisi tujuan dan entitas dari teks yang dikirimkan sebelumnya. Balasan tersebut akan dicocokkan dengan basis data untuk mendapatkan respon yang sesuai. Respon yang dipilih berupa teks kemudian akan diubah kembali menjadi suara dengan *library* Web Speech API yaitu, *Speech*

Synthesis (Wijaya, 2019). Secara umum, skema kerja chatbot Jacob dapat dilihat pada Gambar 2.1.



Gambar 2.1 Skema kerja chatbot Jacob (Wijaya, 2019)

Jacob mengenali 3 jenis pengguna yaitu pengguna biasa atau disebut dengan *user*, admin, dan super admin. Apabila pengguna dikenali oleh Jacob, maka pengguna akan dikategorikan sebagai admin atau super admin dan dapat menambahkan kecerdasan baru atau informasi baru untuk dipelajari oleh Jacob. Sebaliknya, apabila pengguna tidak kenali oleh Jacob, maka pengguna akan dikategorikan sebagai *user* sehingga pengguna hanya dapat bertanya kepada Jacob seputar informasi program *dual degree* Informatika UMN (Wijaya, 2019).

Dengan seluruh kemampuan yang sudah ada, Jacob masih belum memiliki *computer vision*. Oleh karena itu, penelitian ini bertujuan untuk menambahkan *computer vision* dengan *convolutional neural network* untuk pengenalan wajah agar Jacob dapat mengenali penggunanya melalui proses identifikasi wajah.

2.2. Computer Vision

Computer vision adalah ilmu untuk memberikan komputer pengelihatan atau kemampuan untuk melihat (Learned-Miller, 2011). Computer vision terdiri atas *image processing* dan *pattern recognition* (Cosido dkk., 2014). Hasil dari *computer*

vision adalah pemahaman atas gambar. Kebanyakan tugas *computer vision* adalah hal yang berhubungan dengan proses untuk mendapatkan informasi tentang suatu gambar digital.

Tujuan utama dari *computer vision* adalah membuat model, ekstraksi data dan informasi dari gambar, sedangkan *image processing* adalah mengimplementasikan transformasi komputasional untuk gambar seperti penajaman, kontras, dll (Babatunde dkk., 2015). *Pattern recognition* sebagai cabang pembelajaran *computer vision* yang berfokus pada proses identifikasi objek melalui transformasi gambar untuk mendapatkan kualitas gambar yang lebih baik dan interpretasi gambar. Proses ini bertujuan mendapatkan informasi untuk membuat keputusan berdasarkan gambar yang didapatkan dari sensor (Patel dkk., 2012). Secara fungsional, *computer vision* dan penglihatan manusia adalah sama (Ullman dkk., 2016), hanya saja *computer vision* tidak bisa diekspektasikan sesuai seperti replika dari mata manusia (Zhao dkk., 2015) karena terdapat banyak limitasi performa dan fungsi komputer dibandingkan dengan mata manusia.

Computer vision bekerja dengan menggunakan algoritma dan sensor optikal untuk menstimulasikan visualisasi manusia untuk secara otomatis mengambil informasi yang berguna dari objek (Matiacevich dkk., 2013). Dibandingkan dengan cara konvensional yang membutuhkan waktu lama dan membutuhkan analisis, *computer vision* telah berkembang menjadi salah satu cabang dari kecerdasan buatan (*Artificial Intelligence*) dan mensimulasikan visualisasi manusia (Wiley dan Lucas, 2018).

Computer vision dapat diterapkan dalam banyak bidang seperti *quality control* dalam pabrik, *optical character recognition* (OCR), fotografi dan hiburan, *driver*

assistance system, dan *surveillance* (Learned-Miller, 2011). Salah satu contoh konkrit dari penerapan tersebut adalah pengenalan wajah.

2.2.1. Artificial Intelligence

Artificial intelligence (AI) adalah ranah multidisiplin yang bertujuan untuk melakukan otomasi terhadap aktivitas yang membutuhkan kecerdasan manusia (Williams, 1983). Secara sederhana, AI bertujuan untuk memperluas dan menambah kapasitas dan efisiensi dari manusia dalam menata ulang alam dan mengatur masyarakat melalui mesin yang cerdas, dengan tujuan akhir yaitu menyadari bahwa masyarakat adalah manusia dan mesin hidup berdampingan secara harmonis (Bench-Capon dan Dunne, 2007).

Williams (1983) menyatakan bahwa masalah utama dalam dunia AI dapat disimpulkan menjadi *perception*, *manipulation*, *reasoning*, *communication*, dan *learning*. *Perception* berfokus pada membangun model dari dunia nyata dengan masukan sensor. *Manipulation* berfokus pada barang buatan atau imitasi (seperti lengan mekanik, perangkat penggerak) untuk menyesuaikan keadaan pada dunia nyata. *Reasoning* berfokus pada fungsi kognitif yang lebih dalam seperti perencanaan, menggambar konklusi inferensial dll. *Communications* mencoba memahami masalah dan mengambil informasi melalui bahasa. Dan *learning* mencoba untuk meningkatkan performa sistem secara otomatis dari waktu ke waktu berdasarkan pengalaman sistem.

AI telah digunakan untuk beberapa topik penting termasuk *computer vision*, NLP, *science of cognition and reasoning*, *robotic*, *game theory*, dan pembelajaran mesin (Marr, 1977). Meskipun demikian, AI pada saat ini dikenal sebagai AI lemah yang dibuat untuk melakukan pekerjaan tertentu seperti hanya mengenali wajah,

hanya melakukan pencarian internet, atau hanya mengemudi mobil. Apabila AI lemah hanya bisa melakukan pekerjaan manusia yang spesifik, AI secara umum dapat melakukan aktivitas kognitif manusia (Lu dkk, 2017). Tetapi, karena limitasi dari teknologi AI yaitu *frame problem* seperti yang disampaikan oleh Lu dkk. (2017), maka penelitian ini mencoba berfokus untuk mengembangkan salah satu ranah AI yaitu pembelajaran mesin.

2.2.2. Image Processing

Image processing adalah mengimplementasikan transformasi komputasional untuk gambar seperti penajaman, kontras, dll (Babatunde dkk., 2015). *Image processing* menggunakan Teknik analog dapat digunakan untuk *hardcopy* seperti hasil print, dan foto. *Image processing* sangat kuat kaitannya dengan *computer vision* dan *computer graphics* (Kuruville dkk., 2016). Menurut Basavaprasad dan Ravi (2014), tujuan dari *image processing* dapat dibagi menjadi 5 kelompok.

1. *Hallucination* (memantau objek yang tidak terlihat)
2. *Image restoration and sharpening* (membuat gambar menjadi lebih baik)
3. *Image repossession* (mencari gambar yang menarik perhatian)
4. *Measurement of pattern* (mengukur jarak objek dalam gambar)
5. *Image acknowledgement* (membedakan objek dalam gambar)

Menurut Basavaprasad dan Ravi (2014), *image processing* dapat diaplikasikan dalam berbagai hal seperti *image enhancement*, *image restoration*, *image compression*, *character recognition*, *signature verification*, *biometrics*, *fingerprint identification*, *face detection*, dll.

2.2.3. Pattern Recognition

Pattern recognition atau pengenalan pola menitikberatkan pada deskripsi dan klasifikasi dari pengukuran yang diambil dari proses fisik atau mental. Untuk mendapatkan deskripsi yang efektif dan efisien dari pola, *preprocessing* sering digunakan untuk menghilangkan *noise* dan redundansi dalam pengukuran. Kemudian, karakteristik dari pengukuran yang berupa numerik dan atau non-numerik, dan keterkaitan antar pengukuran, diekstraksi untuk representasi dari pola. Klasifikasi atau deskripsi dari pola dengan tujuan yang spesifik dilakukan pada basis representasi (Fu dan Rosenfeld, 1976).

Menurut Jain dkk. (2000), terdapat 4 pendekatan terbaik yang digunakan dalam pengenalan pola sebagai berikut.

1. Template Matching

Salah satu dari pendekatan yang paling sederhana dan paling tua dalam pengenalan pola yaitu berdasarkan *template matching*. Pencocokan adalah operasi umum dalam pengenalan pola yang dilakukan untuk menentukan kesamaan dari dua entitas. *Template* biasanya didapatkan dari *training set*. *Rigid template matching* efektif digunakan dalam beberapa ranah tetapi juga memiliki berbagai kelemahan seperti apabila pola terdistorsi oleh perbedaan sudut pandang, variasi *intra-class* yang banyak dalam pola, ataupun proses *imaging*.

2. Klasifikasi Statistik

Tujuan dari klasifikasi statistik adalah memilih fitur yang memungkinkan vector pola dalam kategori yang berbeda untuk menempati wilayah yang *compact* dan *disjoint* dalam ruang dimensi d .

3. Syntatic Matching/Structural Pattern

Dalam pengembangan pengenalan yang melibatkan pola rumit, lebih mudah untuk melihat dari sudut pandang hirarki bahwa pola terdiri dari subpola yang dimana subpolar terdiri dari subpolar yang lebih sederhana (Fu, 1982). Subpola yang paling sederhana untuk dikenali disebut dengan primitif dan dengan pola yang rumit dipresentasikan dari relasi antara primitif.

4. Neural Network

Jaringan saraf tiruan dapat dilihat sebagai sistem komputasi parallel masif terdiri dari proses sederhana yang besar dengan memiliki banyak interkoneksi (Jain dkk., 2000). Jaringan saraf tiruan yang paling umum digunakan dalam pengenalan pola adalah *feedforward network* diantaranya adalah *multilayer perceptron* dan *Radial-Basis Function networks*. (Jain dkk., 1996). Jaringan saraf tiruan memiliki beberapa kelebihan seperti pendekatan yang digabung untuk ekstraksi fitur dan klasifikasi dan prosedur fleksibel untuk mencari barang, solusi nonlinear yang moderat.

2.3. Pengenalan Wajah

Pengenalan wajah adalah teknologi yang digunakan untuk mengidentifikasi wajah manusia. Wajah manusia adalah satu bentuk dari biometrik sehingga adanya kemungkinan kesamaan dari satu wajah ke wajah lainnya sangat kecil. Terlebih dari itu, Majumdar dan Ward (2008) menyatakan bahwa pengenalan wajah adalah salah satu teknologi biometrik yang tidak intrusif. Zhen dan Su (2009) juga menyatakan bahwa karena kenyamanannya dalam melakukan *sampling* dan juga tidak harus bersentuhan dengan target, sehingga dapat menjadi sangat berguna dan nyaman

untuk digunakan. Bartlett dkk. (2008) menyatakan bahwa ada tiga tahap utama yang digunakan dalam proses pengenalan wajah yaitu:

1. Ekstraksi fitur


Ekstraksi fitur adalah langkah awal dalam pengenalan wajah. Dalam langkah ini, perangkat keras mengambil gambar wajah dan mengirimkannya ke server untuk proses verifikasi dan identifikasi.

2. Kompresi gambar wajah

Gambar yang telah diambil kemudian disimpan dengan ukuran yang kecil untuk verifikasi dan identifikasi.

3. Proses identifikasi

Beberapa gambar contoh yang digunakan untuk membandingkan dengan gambar yang telah diambil untuk proses identifikasi.



Gambar 2.2 Langkah pengenalan wajah (Rathod dkk., 2013)

Rathod dkk. (2013) mengungkapkan bahwa terdapat dua tahap yang berbeda dalam proses pengenalan wajah, yaitu tahap verifikasi dan tahap identifikasi. Proses membandingkan 1:1 untuk menentukan apakah wajah tersebut benar disebut dengan proses verifikasi. Sedangkan, proses identifikasi adalah proses yang membandingkan 1:N wajah yang terdeteksi dengan wajah yang tersimpan dalam media penyimpanan. N merupakan banyaknya gambar wajah latihan yang digunakan dalam proses perbandingan.

Menurut Li dan Zhu (2016), algoritma dalam pengenalan wajah dapat dibagi menjadi 2 kategori menurut cakupan dari ekstraksi fitur.

1. Metode pengenalan berdasarkan fitur lokal dari wajah manusia

Metode ini berdasar kepada deskripsi bentuk dari wajah dan jarak diantaranya untuk mendapatkan fitur yang membantu untuk klasifikasi wajah. Karakteristik dari metode ini biasanya adalah *Euclidean distance* antara titik fitur, lekukan, dan sudut. Wajah manusia terdiri dari mata, hidung, mulut, dagu, dan bagian lainnya. Bagian ini dan deskripsinya secara geometrik dapat digunakan sebagai fitur penting dalam pengenalan wajah.

2. Metode pengenalan berdasarkan fitur global dari wajah manusia

Metode ini bertujuan untuk mendapatkan fitur global dari model muka secara keseluruhan. Pertama, menjelajahi seluruh sampel pelatihan untuk mendapatkan wajah rata-rata dan kemudian melakukan kalkulasi perbedaan muka dari setiap sampel dengan muka rata-rata. Terakhir, mencari nilai vektor orthogonal yang merepresentasikan muka. Salah satu contoh dari metode ini adalah CNN.

Selain itu, Li dan Zhu (2016) juga menyatakan bahwa ekstraksi fitur dapat dibagi menjadi ekstraksi fitur sederhana dan ekstraksi fitur mendalam menurut kedalaman dari ekstraksi fitur.

1. Metode pengenalan berdasarkan ekstraksi fitur sederhana

Metode ini dipakai oleh algoritma pengenalan wajah yang memiliki logika komputasi yang relatif sederhana dan memiliki sedikit konversi seperti Artificial Neural Network. Oleh karena itu, ketika sampel pelatihan dan logika komputasi adalah tetap, khususnya ketika objek target memiliki banyak makna, maka kemampuan untuk menyelesaikan klasifikasi menjadi berkurang.

2. Metode pengenalan berdasarkan ekstraksi fitur mendalam

Dasar dari metode ini dimotivasi dari jaringan saraf tiruan dan simulasi dari otak manusia. Meniru mekanisme bagaimana otak manusia melakukan interpretasi data. Metode ini membentuk fitur abstrak tingkat tinggi dengan mengkombinasikan fitur lapisan bawah. Meskipun terjadi transformasi fitur antar lapisan, sampel ditransformasikan menjadi ruang fitur baru terpisah dari ruang orisinal yang menjadikannya lebih mudah untuk diklasifikasi dan diprediksi. Salah satu contoh metode ini adalah CNN.

Pengenalan wajah dapat diimplementasikan menggunakan berbagai metode. Salah satu metode yang dapat digunakan dan sudah teruji untuk pengenalan wajah adalah yaitu *Convolutional Neural Network* (Chopra dkk., 2005).

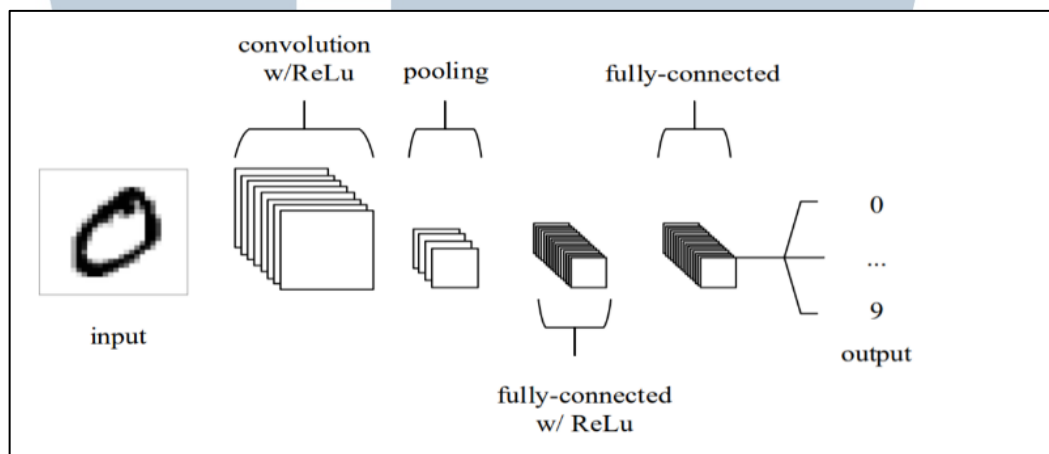
2.4. Convolutional Neural Network (CNN)

CNN sejalan dengan jaringan saraf tiruan atau *Artificial Neural Network* (ANN) tradisional yaitu terdiri dari neuron yang mengoptimasi diri sendiri dengan pembelajaran. Setiap neuron tetap akan menerima masukan dan melakukan sebuah operasi. Perbedaan yang paling dapat dilihat dari CNN adalah CNN digunakan dalam ranah pengenalan pola dalam gambar. Hal ini memungkinkan untuk melakukan *encode* fitur gambar yang spesifik kedalam arsitektur yang membuat jaringan menjadi lebih cocok untuk pekerjaan yang berfokus pada gambar sekaligus mengurangi parameter yang dibutuhkan untuk membuat model (O'Shea dan Nash, 2015).

U N I V E R S I T A S
M U L T I M E D I A
N U S A N T A R A

2.4.1. Arsitektur

Secara umum, CNN terdiri dari 3 jenis lapisan yaitu, *convolutional layers*, *pooling layers*, dan *fully-connected layers*. Ketika lapisan ini ditumpuk, maka arsitektur CNN telah terbentuk (O'Shea dan Nash, 2015). CNN memiliki berbagai macam arsitektur yang telah dikembangkan hingga saat ini. Beberapa diantaranya adalah Inception, Residual Network (ResNet), LeNet, AlexNet, dan lain-lain. Arsitektur CNN yang telah disederhanakan untuk klasifikasi MNIST dapat dilihat pada gambar dibawah.



Gambar 2.3 Arsitektur CNN sederhana, terdiri dari 5 lapisan gambar (O'Shea dan Nash, 2015)

Fungsi dasar dari contoh CNN diatas dapat dibagi menjadi 4 bagian utama (O'Shea dan Nash, 2015).

1. Seperti bentuk ANN lainnya, lapisan masukan akan berisi nilai piksel dari gambar.
2. *Convolutional layer* akan menentukan jumlah neuron yang terhubung dengan daerah local dari input dengan menghitung hasil skalar dari bobot dan bagian yang terhubung. Rectified linear unit (biasa disingkat ReLu) bertujuan untuk melakukan fungsi aktivasi untuk keluaran dari lapisan sebelumnya.

3. *Pooling layer* akan melakukan *downsampling* pada dimensi spasial dari *input* yang telah diberikan, mengurangi lebih banyak parameter dari aktivasi.
4. *Fully-connected layer* akan bekerja seperti ANN standar dan mencoba menghitung nilai kelas dari aktivasi untuk digunakan sebagai pengklasifikasi. Disarankan bahwa ReLu dapat digunakan antar lapisan ini untuk meningkatkan performa.

Convolutional Neural Network yang digunakan pada kasus pengenalan wajah pasti memiliki tingkat presisi dalam mengukur kemiripan wajah yang diukur berdasarkan hasil pembelajarannya. Oleh karena itu, dapat dilakukan evaluasi pengenalan yang dilakukan oleh Convolutional Neural Network dengan metode *F-Measure*.

2.4.2. FaceNet

Berdasarkan penelitian yang dilakukan oleh Schroff dkk. (2015), FaceNet adalah sistem *Deep CNN* yang langsung mempelajari pemetaan dari gambar wajah menjadi ruang Euclid yang padat dimana jarak langsung berkorespondensi dengan pengukuran kesamaan wajah. Untuk pelatihan, FaceNet menggunakan triplets dari gambar wajah yang diluruskan secara kasar dihasilkan dari metode *novel online triplet mining*. Dengan pendekatan itu, maka didapatkan efisiensi representasional yang lebih besar.

Metode ini berdasarkan dari pembelajaran penyematan *Euclidean* dari setiap gambar menggunakan *Deep Convolutional Network*. *Triplets loss* berfungsi untuk mencoba membuat *margin* antara setiap pasang muka dari satu orang kewajah lainnya. Ini memungkinkan wajah dari satu identitas untuk tetap terus ada dalam

manifold, tetapi tetap terus membuat jarak dan dengan demikian menyingkirkan identitas lainnya.

Telah dibuktikan oleh Schroff dkk. (2015) bahwa sistem FaceNet dapat mencapai rekor, yaitu 99.63% dengan menggunakan basis data *Labeled Faces in the Wild* (LFW) dan YouTube Faces mencapai 95.12%. Schroff dkk. menunjukkan dari hasil penelitian Sun dkk. (2014) menggunakan berbagai macam algoritma seperti DeepID2, GaussianFace, DeepID, dll., bahwa FaceNet memiliki tingkat error yang lebih rendah sebesar 30% untuk kedua database. Hasil dari penelitian Sun dkk. dapat dilihat pada Tabel 2.1 dan Tabel 2.2. Oleh karena itu, penelitian ini memutuskan untuk menggunakan FaceNet dalam melakukan pengenalan wajah.

Tabel 2.1 Hasil dengan LFW (Sun dkk., 2014)

Metode	Akurasi (%)
High-dim LBP	95.17 ± 1.13
TL Joint Bayesian	96.33 ± 1.08
DeepFace	97.35 ± 0.25
DeepID	97.45 ± 0.26
GaussianFace	98.52 ± 0.66
DeepID2	99.15 ± 0.13
DeepID2+	99.47 ± 0.12

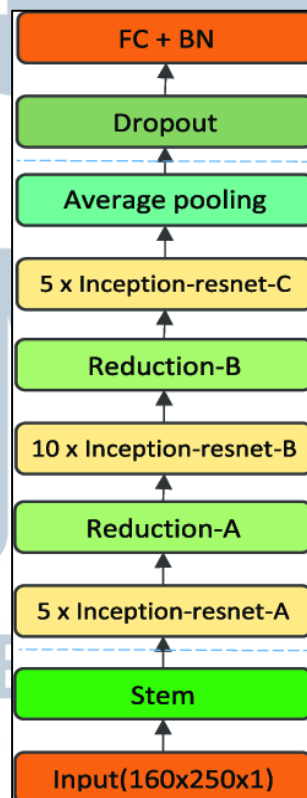
Tabel 2.2 Hasil dengan YouTube Faces (Sun dkk., 2014)

Metode	Akurasi (%)
LM3L	81.3 ± 1.2
DDML (LBP)	81.3 ± 1.6
DDML (kombinasi)	82.3 ± 1.5
EigenPEP	84.8 ± 1.4
DeepFace-single	91.4 ± 1.1
DeepID2+	93.2 ± 0.2

Berdasarkan *library* FaceNet yang diimplementasikan oleh Sandberg (2017) yang dapat dilihat pada GitHub, *library* ini menggunakan *Multi-task Cascaded Convolutional Network* (MTCNN) untuk pemerataan dan pemotongan gambar serta *pre-whiten* untuk membantu ekstraksi fitur.

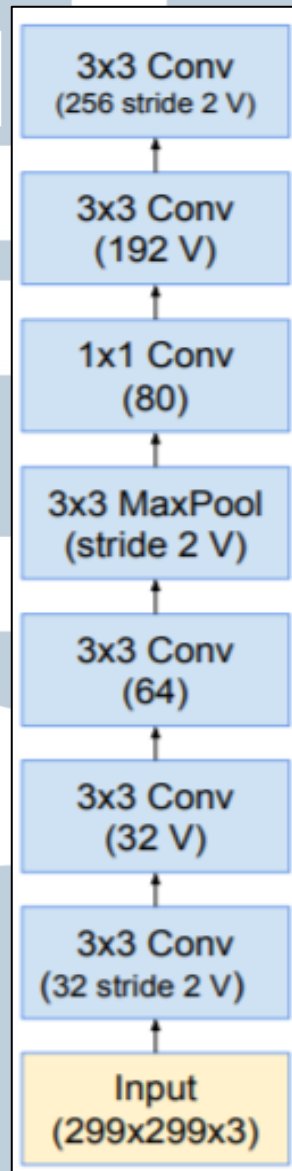
2.4.3. Inception-ResNet-v1

Inception-ResNet-v1 adalah versi *hybrid* Inception yang memiliki beban komputasional yang mirip dengan Inception-v3. Inception-ResNet-v1 adalah sebuah arsitektur CNN gabungan dari Inception dan Residual Network. Tujuan dari menggabungkan Residual Network kedalam Inception adalah untuk mempercepat proses latihan (Szegedy, 2015). Skema arsitektur Inception-ResNet-v1 digambarkan pada Gambar 2.4.



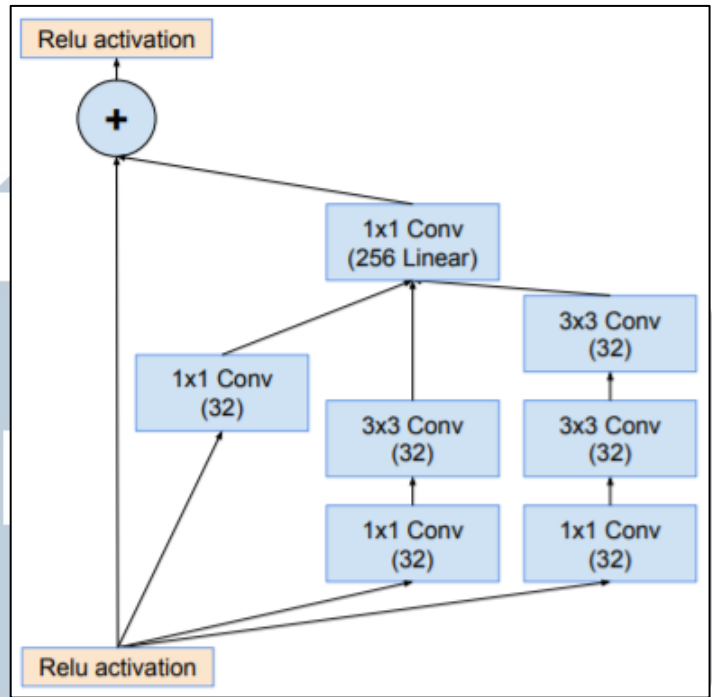
Gambar 2.4 Skema keseluruhan arsitektur Inception-ResNet-v1

Stem yang terdapat pada Gambar 2.4 adalah arsitektur Inception yang diimplementasikan dalam Inception-ResNet-v1. Gambar 2.5 menjabarkan *stem* yang digunakan dalam Inception-ResNet-v1.

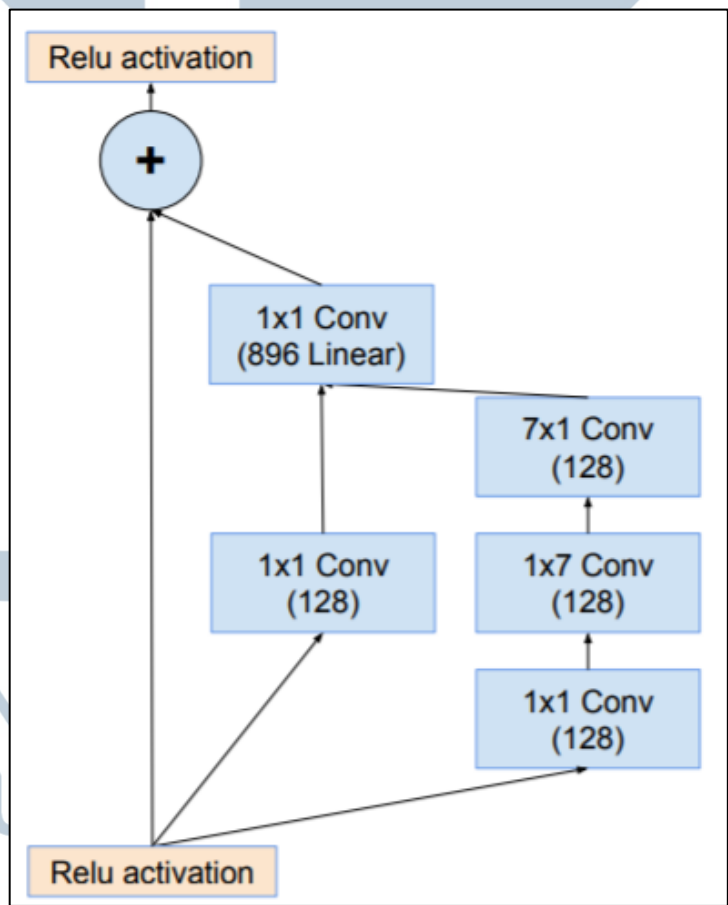


Gambar 2.5 Stem Inception-ResNet-v1

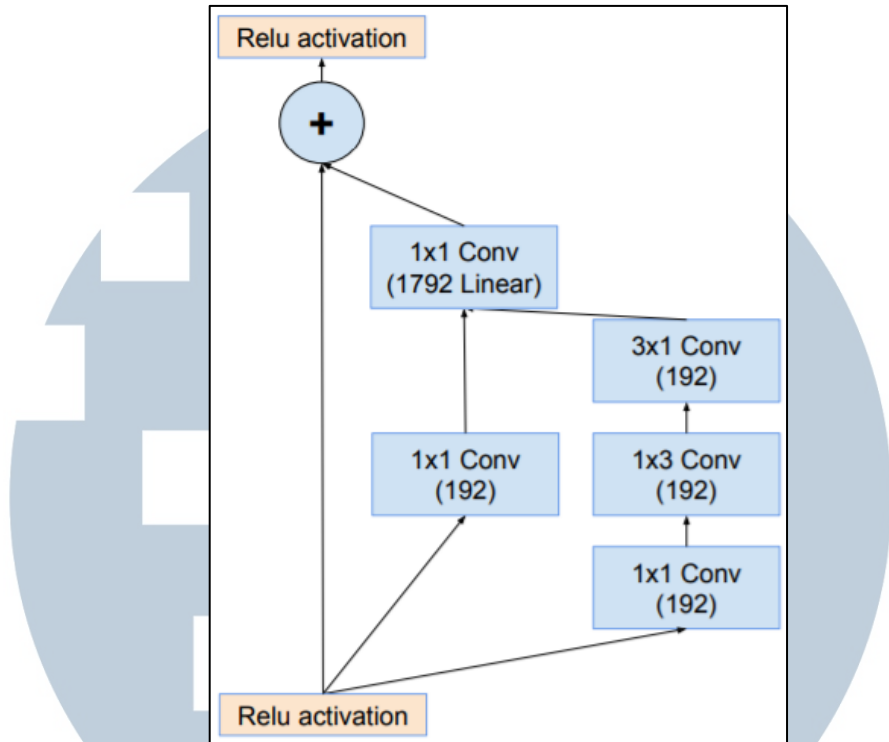
Setelah *stem* selesai dikerjakan, terdapat 3 modul dari Inception-ResNet-v1 yaitu, Inception-ResNet-A, Inception-ResNet-B, Inception-ResNet-C yang dijabarkan pada Gambar 2.6, Gambar 2.7, dan Gambar 2.8. 3 modul tersebut adalah Residual Network pada arsitektur Inception-ResNet-v1.



Gambar 2.6 Inception-ResNet-A

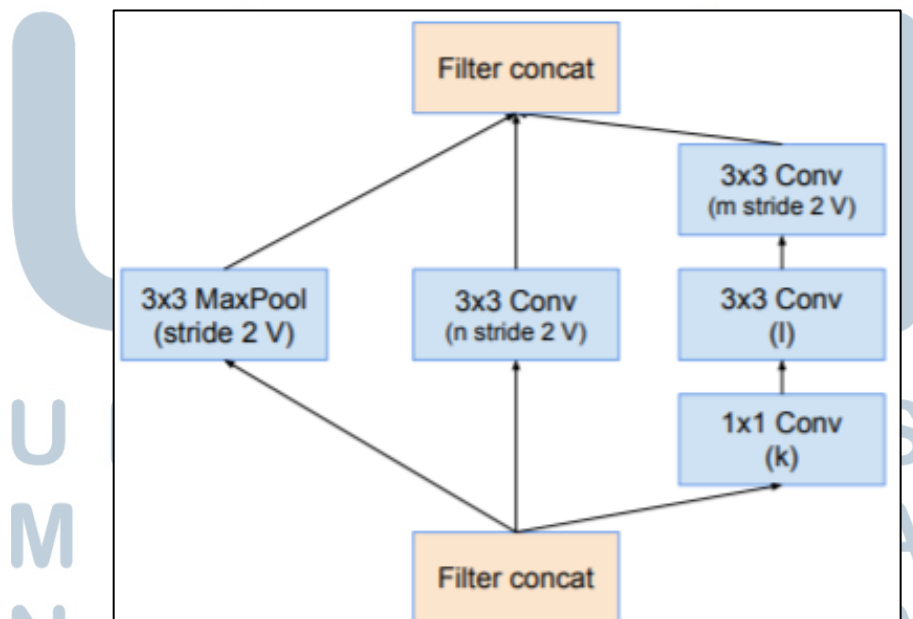


Gambar 2.7 Inception-ResNet-B

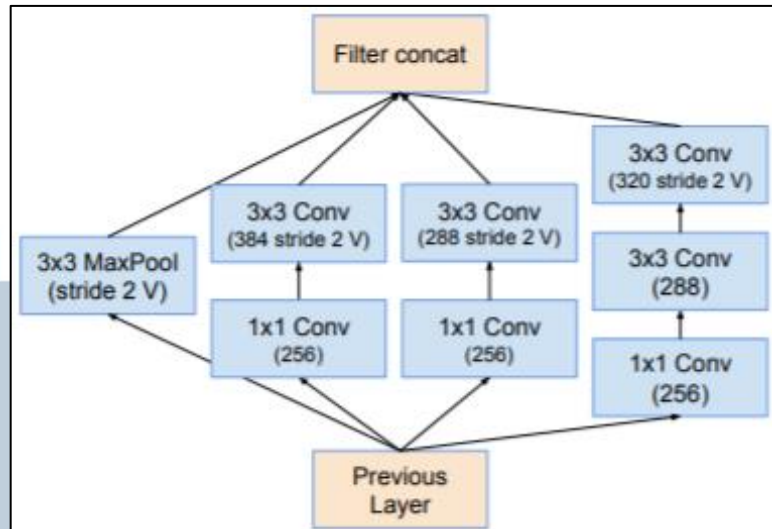


Gambar 2.8 Inception-ResNet-C

Selain 3 modul Residual Network terdapat *reduction block* untuk memperkecil dimensi. *Reduction block* terbagi atas 2, yaitu Reduction-A dan Reduction-B yang dijabarkan dalam Gambar 2.9 dan 2.10.



Gambar 2.9 Reduction-A



Gambar 2.10 Reduction-B

Setelah Residual Network dan *reduction block* selesai, maka akan ditambahkan lapisan *dropout* untuk memastikan bahwa jaringan yang dibangun tidak *overfit* pada data latih. Pada lapisan terakhir ditambahkan lapisan *fully connected* untuk menghubungkan semua neuron yang telah dilatih sehingga dapat mendeteksi fitur tingkat tinggi.

2.5. Algoritma Least Recently Used

Page replacement algorithm adalah algoritma yang digunakan untuk menentukan sebuah memori untuk dibuang dan ditulis (Khulbe dan Pant, 2014). Terdapat beberapa *page replacement algorithm* seperti *first in first out* (FIFO), *optimal*, *second chance*, *clock*, *Least Recently Used* (LRU), dan lain-lain (Khosrozadeh dkk., 2012).

Algoritma LRU berdasar kepada fakta bahwa *page* yang banyak digunakan dalam beberapa perintah terakhir, kemungkinan akan digunakan lagi dalam beberapa perintah berikutnya. Sebaliknya, *page* yang tidak digunakan dalam waktu yang lama, kemungkinan akan tetap tidak digunakan (Khosrozadeh dkk., 2012).

Oleh karena itu, LRU memiliki kebijakan dengan menggantikan *page* yang tidak digunakan berdasarkan waktu yang paling lama (O'Neil dkk., 1996). Secara umum, LRU memiliki performa yang lebih baik daripada algoritma FIFO (Khulbe dan Pant, 2014). LRU adalah *page replacement algorithm* yang umum dipakai dan termasuk salah satu algoritma yang sukses (Khosrozadeh dkk., 2012). Meskipun memiliki performa yang baik, algoritma ini sulit dan mahal untuk diimplementasikan (O'Neil dkk., 1996).

Tabel 2.3 Representasi LRU untuk 3 *frame*

7	0	1	2	0	3	0	4	2	3	0	3	2	1	2	0	1	7	0	1
7	7	7	2		2		4	4	4	0			1		1				
	0	0	0		0		0	0	3	3			3		0				0
		1	1		3		3	2	2	2			2		2				7

2.6. F-Measure

F-Measure merupakan pengukuran rata-rata harmonik antara *precision* dan *recall* (Manning, 1999).

Tabel 2.4 Matriks kontingensi 2x2 (Manning, 1999)

<i>System</i>	<i>Actual</i>	
	<i>Target</i>	<i>Not target</i>
<i>Selected</i>	<i>True positive (tp)</i>	<i>False positive (fp)</i>
<i>Not selected</i>	<i>False negative (fn)</i>	<i>True negative (tn)</i>

Precision adalah tingkat ketepatan antara informasi yang diminta oleh pengguna dengan jawaban yang diberikan oleh sistem atau secara sederhana adalah jumlah sampel berkategori positif diklasifikasi benar dibagi dengan total sampel yang diklasifikasi sebagai sampel positif. *Precision* didefinisikan sebagai berikut (Manning, 1999).

$$Precision = \frac{tp}{tp+fp} \quad \dots(2.1)$$

Recall adalah tingkat keberhasilan sistem dalam menemukan kembali sebuah informasi atau secara sederhana adalah jumlah sampel diklasifikasi positif dibagi total sampel dalam *testing* set berkategori positif. *Recall* didefinisikan sebagai berikut (Manning, 1999).

$$Recall = \frac{tp}{tp+fn} \quad \dots(2.2)$$

Dari tabel kontingensi, F-Measure didefinisikan sebagai berikut (Manning, 1999).

$$F = \frac{1}{\alpha \frac{1}{P} + (1-\alpha) \frac{1}{R}} = \frac{2PR}{(R+P)} \quad \dots(2.3)$$

Dimana P adalah *precision*, R adalah *recall* dan α adalah faktor yang menentukan pembobotan dan *precision* dan *recall*. Jika nilai F mendekati nol, maka *precision* dan *recall* yang dimiliki buruk dan sebaliknya apabila nilai mendekati satu, maka *precision* dan *recall* yang dimiliki baik.

U N I V E R S I T A S
M U L T I M E D I A
N U S A N T A R A