



**IMPLEMENTASI *DEEP LEARNING* DALAM *DIGITAL IMAGE*
PROCESSING RETINA MATA UNTUK DETEKSI KELAINAN
PADA MAKULA**

SKRIPSI

Disusun sebagai salah satu syarat
Untuk memperoleh gelar Sarjana Sains
Program Studi Matematika

Oleh

Mien Fatimah Az-zahra
4111415029

**JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS NEGERI SEMARANG
2019**

PERNYATAAN

Saya menyatakan bahwa skripsi ini bebas plagiat. Apabila di kemudian hari terbukti terdapat plagiat dalam skripsi ini, maka saya bersedia menerima sanksi sesuai dengan ketentuan peraturan perundang-undangan yang berlaku.



Semarang, 9 Agustus 2019

Mien Fatimah Az-zahra

4111415029

PENGESAHAN

Skripsi yang berjudul

Implementasi *Deep Learning* dalam *Digital Image processing* Retina
Mata untuk Deteksi Kelainan pada Makula

disusun oleh

Mien Fatimah Az-zahra

4111415029

telah dipertahankan di hadapan sidang Panitia Ujian Skripsi FMIPA Universitas
Negeri Semarang pada tanggal 12 Agustus 2019.



Panitia,

Dr. Bugianto, M.Si.

NIP. 196102191993031001

Ketua Penguji

Dr. Scolastika Mariani, M.Si.

NIP. 196502101991022001

Anggota Penguji/

Penguji II

Dr. Walid, S.Pd., M.Si.

NIP. 197408192001121001

Sekretaris

Dr. Arief Agoestanto, M.Si.

NIP. 196807221993031005

Anggota Penguji/

Pembimbing

Dr. Iqbal Kharisudin, S.Pd., M.Sc.

NIP. 197908052005011003

MOTTO DAN PERSEMBAHAN

MOTTO

1. Man Jadda Wa Jadda
2. There is no power nor might except with Allah
3. And He found you lost and guided you
(QS. Ad-Dhuha:7)
4. Allah akan meninggikan orang-orang yang beriman di antaramu dan orang-orang yang diberi ilmu beberapa derajat. Dan Allah Maha Mengetahui apa yang kamu kerjakan.
(QS. Al Mujadilah (58): 11)

PERSEMBAHAN

1. Kedua orang tua tercinta, Bapak Karmain dan Ibu Endang Susilowati yang tidakhenti mendoakan dan mendukung dan memotivasi.
2. Kakak-kakak tercinta Vita Mariza Fitriana dan Riayatul Hazna Sahaningrum yang selalu mendukung.
3. Adik tersayang, Mayla Puspita Ningrum
4. Sahabat-sahabatku, Asmel, Mila, Vidya, Eka, Jefri, Alif, Hendrik,yang telah menguatkan pada setiap langkah perjuangan.
5. Teman-temanmatematika 2015.

PRAKATA

Puji syukur kehadiran Allah SWT yang telah melimpahkan rahmat dan karunia-Nya sehingga penulis dapat menyelesaikan skripsi yang berjudul “Implementasi *Deep Learning* dalam *Digital Image Processing* Retina Mata untuk Deteksi Kelainan pada Makula”. Shalawat serta salam senantiasa tercurah kepada Nabi Agung Muhammad SAW, semoga kita dapat memperoleh syafa’atnya kelak. Penyelesaian skripsi ini tidak lepas dari bantuan, dukungan, dan sumbangan pemikiran dari berbagai pihak. Oleh karena itu, penulis menyampaikan terima kasih kepada:

1. Prof. Dr. Fathur Rokhman, M.Hum., Rektor Universitas Negeri Semarang.
2. Dr. Sugianto, M.Si., Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Semarang.
3. Drs. Arief Agoestanto, M.Si., Ketua Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Semarang.
4. Dr. Iqbal Kharisudin, S.Pd., M.Sc., Dosen Pembimbing yang telah memberikan bimbingan, arahan, saran, dan motivasi kepada penulis dalam menyusun skripsi.
5. Dr. Scolastika Mariani, M.Si. dan Dr. Walid, S.Pd., M.Si., sebagai Dosen Penguji yang telah memberikan saran dalam penyusunan skripsi.
6. Prof. Dr. St. Budi Waluya, M.Si., Dosen Wali yang telah memberikan bimbingan dan motivasi selama penulis menjalankan studi.
7. Seluruh Dosen Jurusan Matematika atas ilmu yang telah diberikan selama menempuh studi.
8. Bapak, Ibu, kakak, adik, dan keluarga yang selalu mendoakan dan memberikan motivasi.
9. Teman-teman Jurusan Matematika angkatan 2015.
10. Semua pihak yang tidak dapat penulis sebutkan satu per satu yang telah memberikan bantuan, motivasi, dan do’a kepada penulis.

Semoga skripsi ini dapat memberikan manfaat bagi penulis dan para pembaca. Terima kasih.

Semarang, 9 Agustus 2019

Penulis

ABSTRAK

Az-zahra, Mien Fatimah. 2019. Implementasi *Deep Learning* dalam *Digital Image Processing* Retina Mata untuk Deteksi Kelainan pada Makula. Skripsi, Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Negeri Semarang, Pembimbing Dr. Iqbal Kharisudin, S.Pd., M.Sc.

Kata kunci: *Deep Neural Network*, *Digital Image Processing*, Retina Mata, Python.

Penelitian ini menggunakan data sekunder yang bertujuan merancang sistem untuk mengenali kondisi retina mata normal ataupun penyakit CNV, DME, dan Drusen yang dihasilkan alat *Optical Coherence Tomography* (OCT). Sistem akan menghasilkan model training, evaluasi, dan nilai akurasi. Metode yang digunakan adalah *Convolution Neural Network* dengan *default parameter* 50 *epoch*, 1 *stride*, 83484 citra data *train*, dan nilai *learning rate* 0,001 dengan bantuan software Python 3.7. Pengujian dengan menggunakan variasi *epoch*, *stride*, banyak data *train*, dan nilai *learning rate* menghasilkan nilai akurasi yang berbeda. Berdasarkan variasi *epoch* tingkat akurasi terbaik adalah 50 *epoch* dengan nilai akurasi 0,99 dan *loss* validasi 0,2034, variasi nilai *stride* tingkat akurasi terbaik adalah 1 *stride* dengan nilai akurasi 0,99 dan *loss* validasi 0,2267, variasi data *train* tingkat akurasi terbaik adalah 83484 gambar dengan nilai akurasi 0,99 dan nilai *loss* validasi 0,2524, dan nilai variasi *learning rate* tingkat akurasi terbaik adalah 0,0001 dengan nilai akurasi 0,992 dan nilai *loss* validasi 0,2524 Berdasarkan hasil penelitian diperoleh (1) Arsitektur *convolution neural network* (2) model terbaik dengan nilai akurasi 0,992 berdasarkan variasi parameter 50 *epoch*, 1 *stride*, 83484 citra data *train* dan *learning rate* 0,0001.

DAFTAR ISI

HALAMAN DEPAN	i
PERNYATAAN	ii
PENGESAHAN	iii
MOTTO DAN PERSEMBAHAN	iv
PRAKATA	v
ABSTRAK	vii
DAFTAR TABEL	xi
DAFTAR GAMBAR	xii
DAFTAR LAMPIRAN	xiv
PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Perumusan Masalah	6
1.3 Batasan Masalah	6
1.4 Tujuan Penulisan	7
1.5 Manfaat Penulisan	7
BAB II TINJAUAN PUSTAKA	8
2.1 Data Mining	8
2.2 Pembelajaran Statistika	10
2.2.1 <i>Supervised Learning</i>	11
2.2.2 <i>Semi-supervised Learning</i>	12
2.2.3 <i>Unsupervised Learning</i>	13
2.3 Pengolahan Citra	13
2.4 <i>Artificial Neural Network</i>	15
2.5 <i>Deep Neural Network</i>	20
2.6 <i>Convolutional Neural Network</i>	21
2.6.1 <i>Convolution Layer</i>	22
2.6.2 Fungsi Aktivasi	23
2.6.3 <i>Pooling Layer</i>	25

2.6.4	<i>Fully Connected Layer</i>	26
2.6.5	<i>Hyperparameter</i>	26
2.7	Identifikasi Penyakit Retina	26
2.7.1	<i>Choroidal Neovascularization (CNV)</i>	27
2.7.2	<i>Diabetic Macular Edema (DME)</i>	28
2.7.3	<i>Drusen</i>	29
2.8	<i>Optical Coherence Tomography (OCT)</i>	30
2.9	<i>Python</i>	31
2.9.1	<i>Anaconda</i>	32
2.9.2	<i>TensorFlow</i>	33
2.10	<i>Confussion Matrix</i>	34
2.11	Penelitian Terdahulu	35
BAB IIIMETODE PENELITIAN		38
3.1	Penentuan Masalah.....	38
3.2	Perumusan Masalah.....	38
3.3	Studi Pustaka	39
3.4	Data	39
3.5	Variabel dan Definisi Operasional Variabel	39
3.6	Jenis dan Sumber Data	40
3.7	Metode Analisis Data	40
3.8	Tahapan penelitian	40
3.9	Analisis dan Pemecahan Masalah	41
3.10	Program <i>Python</i>	42
3.11	Perangkat Pengujian	44
3.12	Tahapan pengujian Model	44
3.13	Penarikan Kesimpulan.....	45
BAB IVHASIL DAN PEMBAHASAN		46
4.1	Arsitektur Jaringan	46
4.2	Sistem Pengenalan Pola	47
4.2.1	Extract Features	47
4.2.2	Proses Training Data	51

4.2.3 Proses Evaluasi	57
4.3 Mekanisme <i>Training</i> dan Evaluasi Data	61
4.3.1 Variasi <i>Epoch</i>	62
4.3.2 Variasi <i>Stride</i>	63
4.3.3 Variasi Data <i>Train</i>	63
4.3.4 Variasi <i>Learning Rate</i>	64
4.4 Hasil <i>Testing</i>	65
BAB VKESIMPULAN DAN SARAN	66
5.2 Kesimpulan	66
5.2 Saran	67
DAFTAR PUSTAKA	68
Lampiran 1 <i>Output</i> data training dengan default parameter	75

DAFTAR TABEL

Tabel 2.1 <i>Confussion matrix</i> pada <i>binary</i> klasifikasi	34
Tabel 3.1 Data penelitian	39
Tabel 3.2 Definisi Operasional Variabel.....	39
Tabel 3.3 <i>Package</i> dan fungsinya	44
Tabel 3.4 <i>Confussion matrix</i>	45
Tabel 4.1 Nilai default parameter	62
Tabel 4.2 Nilai akurasi berdasarkan pengaruh banyak <i>epoch</i>	62
Tabel 4.3 Nilai akurasi berdasarkan pengaruh banyak <i>stride</i>	63
Tabel 4. 4 Nilai akurasi berdasarkan pengaruh banyak data <i>train</i>	64
Tabel 4.5 Nilai akurasi berdasarkan pengaruh nilai <i>learning rate</i>	64
Tabel 4.6 <i>Confussion matriks</i> pada model “model.features.47-0.99.hdf5”	65

DAFTAR GAMBAR

Gambar 1.1 Struktur anatomi mata manusia.....	4
Gambar 1.2 Optical Coherence Tomography	5
Gambar 2.1 Tahapan proses KDD	9
Gambar 2.2 <i>Supervised learning-mathematical explanation</i>	11
Gambar 2.3 <i>Supervised learning – mathematical explanation 2</i>	11
Gambar 2.4 <i>Supervised learning framework</i>	12
Gambar 2.5 <i>Unsupervised learning framework</i>	13
Gambar 2.6 Koordinat citra digital	14
Gambar 2.7 Jaringan saraf	15
Gambar 2.8 Model struktur JST.....	16
Gambar 2.9 Arsitektur <i>Neural network</i>	17
Gambar 2.10 <i>Single perceptron</i>	18
Gambar 2.11 <i>Multilayer perceptron</i>	19
Gambar 2.12 <i>Competitive Layer</i>	20
Gambar 2.13 <i>Deep neural network</i>	20
Gambar 2.14 Alur kerja <i>deep neural network</i>	21
Gambar 2.15 Arsitektur <i>Convolutional Neural Network</i>	21
Gambar 2.16 Ilustrasi <i>input convolution layer</i>	22
Gambar 2.17 <i>input convolution</i>	23
Gambar 2.18 Fungsi aktivasi ReLU.....	24
Gambar 2.19 ilustrasi fungsi aktivasi softmax.....	25
Gambar 2.20 Operasi <i>max pooling</i>	25
Gambar 2.21 gambar retina normal	27
Gambar 2.22 Gambar CNV dengan menggunakan pemindaian OCT.....	28
Gambar 2.23 Gambar DME dengan menggunakan pemindaian OCT	29
Gambar 2.24 Gambar <i>Drusen</i> dengan menggunakan pemindaian OCT	30
Gambar 2.25 Konsep <i>Module</i> dan <i>Package</i>	32
Gambar 2.26 Tampilan <i>anaconda navigator</i>	33
Gambar 2.27 Tabel prediksi dan eror.....	35

Gambar 2.28 Penelitian Terdahulu	37
Gambar 3.1 Tahapan Penelitian	41
Gambar 3.2 Tampilan halaman depan <i>anaconda navigator</i>	43
Gambar 3.3 Halaman depan <i>jupyter notebook</i>	43
Gambar 3.4 <i>Directory data</i>	44
Gambar 3.5 <i>Script</i> Arsitektur CNN.....	45
Gambar 4.1 Arsitektur jaringan	46
Gambar 4.2 Grafik nilai akurasi <i>training</i> dan <i>validation</i>	56
Gambar 4.3 Grafik nilai loss <i>training</i> dan <i>validation</i>	57

DAFTAR LAMPIRAN

Lampiran 1 <i>Output</i> data training dengan default parameter	75
---	----

BAB I

PENDAHULUAN

1.1 Latar Belakang

Pembelajaran statistika atau lebih dikenal dengan *statistical learning* saat ini sudah banyak dikembangkan. Sejalan dengan perkembangan ilmu komputer, *statistical learning* memainkan peran penting dalam berbagai ilmu pengetahuan, industri, dan ekonomi.

Statistical learning merupakan seperangkat alat untuk memodelkan dan memahami kumpulan data yang kompleks (James dkk., 2017). Saat ini banyak data yang dihasilkan setiap hari dari berbagai sektor seperti pemerintahan, bank, rumah sakit, perusahaan, dan lain sebagainya, namun masih kurang dalam pengelolaannya. Oleh karena itu, dibutuhkan metode untuk mengekstrak pengetahuan dan atau menemukan pola dari himpunan data yang banyak tersebut.

Perkembangan teknologi saat ini tidak kalah cepat, seperti perkembangan teknologi *Artificial Intelligence* (AI). *Artificial Intelligence* (AI) merupakan salah satu teknologi yang mendukung kehidupan sosial dan ekonomi. Beberapa tahun terakhir AI telah dikembangkan di negara-negara maju seperti Eropa dan Amerika Serikat dan Negara-negara berkembang seperti Cina dan India (Lu dkk., 2018). Salah satu aplikasi AI adalah potensi untuk merevolusi diagnosis dan manajemen penyakit. AI melakukan klasifikasi untuk membantu para ahli dalam mengambil keputusan. Cara kerja AI dimulai dengan meninjau sejumlah besar gambar. Kemudian dengan menggunakan *transfer learning*, data dilatih dengan jaringan saraf tiruan (JST). Setelah terbangun model JST dilakukan test dengan menggunakan data yang ingin di uji. Oleh karena itu dengan adanya teknologi AI membantu mempercepat diagnosis dan rujukan dari kondisi yang di alami pasien (Kermany dkk., 2018).

Saat ini sudah banyak bermunculan aplikasi-apikasi komputasi statistik. Salah satunya adalah pada bidang teknologi pengenalan pola menggunakan *neural network* dan sudah diterapkan di berbagai bidang ilmu pengetahuan. Beberapa

penelitian tentang *neural network* adalah penelitian Bodyanskiy dkk. (2017) tentang *fuzzy clustering data arrays* pada data pengamatan yang hilang. Penelitian Acharya dkk. (2018) tentang implementasi CNN untuk deteksi otomatis dan diagnosis kejang menggunakan sinyal EEG.

Teknologi pengenalan pola atau *pattern recognition* merupakan salah satu bidang dalam *machine learning*. Pengenalan pola menitikberatkan pada deskripsi dan klasifikasi dari suatu pengukuran. Pengenalan pola dapat dimanfaatkan untuk mengklasifikasikan gambar, teks, suara, dan lain sebagainya.

Pengenalan pola pada citra digital merupakan salah satu proses pengolahan citra dengan menggunakan komputer. Citra merupakan gambar pada bidang dua dimensi yang dihasilkan dari gambar analog dua dimensi dan kontinu menjadi gambar diskrit melalui proses sampling. Secara matematis citra digital dapat ditulis dalam bentuk matriks sebagai berikut.

$$f(x, y) = \begin{bmatrix} f(0,0) & f(0,1) & \cdots & f(0, N-1) \\ f(1,0) & f(1,1) & \cdots & f(1, N-1) \\ \vdots & \vdots & \ddots & \vdots \\ f(M-1, 0) & f(M-1, 1) & \cdots & f(M-1, N-1) \end{bmatrix}$$

dengan $f(x, y)$ merupakan besar intensitas yang diterima sensor di setiap titik piksel (x, y) , dan $0 < f(x, y) < \infty$.

Penelitian yang membahas tentang pengenalan pola di antaranya adalah penelitian yang dilakukan oleh Rastegari dkk. (2016) tentang klasifikasi gambar menggunakan *binary convolutional neural network*, dan Coudray dkk. (2018) tentang klasifikasi dan prediksi mutasi dari histopatologi gambar kanker paru-paru pada *non-small cell* menggunakan *deep learning*. Metode yang dapat mengenali pola berdasarkan gambar atau audio yang dihasilkan adalah dengan menggunakan metode *neural network*.


Artificial Neural network (ANN) merupakan algoritma yang memiliki cara kerja yang sama seperti cara otak manusia bekerja. Setiap neuron pada otak manusia saling berhubungan dan informasi mengalir dari setiap neuron tersebut (Ciaburro dan Venkateswaran, 2017). *Artificial Neural network* memiliki kemampuan untuk mempelajari dependensi secara langsung dari data yang belum pernah dipelajari. *Artificial Neural network* terdiri atas banyak unit pemrosesan

sederhana yang memiliki kecenderungan alami untuk menyimpan pengetahuan, pengalaman dan dapat diandalkan seperti otak manusia (Haykin, 2014). Definisi lain tentang ANN adalah menurut Kriesel (2005) yaitu himpunan (N, V, w) dengan N himpunan *neuron*, V himpunan $\{(i, j) | i, j \in \mathbb{N}\}$ dengan setiap elemen disebut koneksi antara *neuron* i dan *neuron* j , dan fungsi $w: V \rightarrow \mathbb{R}$ mendefinisikan bobot $w(i, j)$ yang merupakan bobot koneksi antara *neuron* i dan *neuron* j .

Pengenalan pola dapat diterapkan dalam berbagai bidang, salah satunya adalah pada bidang kedokteran (lihat Donahue dkk. (2014), Krizhevsky dkk. (2012), Ghupta dan Choubey (2015)). Karena data-data yang dihasilkan pada bidang kedokteran seperti data pasien dan penyakit setiap harinya bisa mencapai ribuan bahkan jutaan. Salah satu data yang dihasilkan berasal dari bidang optalmologi.

Optalmologi adalah spesialisasi ilmu kedokteran yang berkonsentrasi pada diagnosa penanganan dan pencegahan serta cedera yang dialami mata. Optalmologi merupakan salah satu bidang kedokteran yang mengharuskan dokter menguasai dua spesialisasi sekaligus yaitu spesialis mata dan spesialis dokter bedah (Gelatt dkk. 2012).

Optalmologi erat hubungannya dengan mata, dengan mata merupakan salah satu alat indra yang vital bagi manusia. Mata merupakan alat indra yang berfungsi untuk melihat berbagai objek yang ada disekitar. Mata terdiri atas beberapa bagian vital seperti Kornea, Iris, Pupil, Aquerous Humor, Lensa, Otot Siliari, Retina, Saraf Optik, Bintik buta, Makula dan Fovea (*point of Central focus*), semua bagian-bagian tersebut memiliki peran yang berbeda-beda dalam proses masuknya cahaya sampai akhirnya manusia bisa melihat. Gambar 1.1 menunjukkan struktur anatomi mata pada manusia (Michael F. Land dan Fernald, 1997).



Gambar1.1 Struktur anatomi mata manusia
 (<https://www.sridianti.com/apa-fungsi-bagian-mata-manusia.html>)

Seiring munculnya berbagai jenis penyakit *degeneratif* akan sejalan dengan pesatnya perkembangan alat medis. Penyakit degeneratif merupakan penyakit yang menyebabkan terjadinya kerusakan atau penghancuran terhadap jaringan atau organ tubuh. Munculnya penyakit degeneratif disebabkan perubahan pola hidup yang tidak sehat dan tingkat stress yang tinggi (Harahap dan Andayani, 2018). Beberapa penyakit *degeneratif* yang menyerang mata adalah *Choroidal Neovascularization* (CNV), *Diabetic Macular Edema* (DME) dan *Drusen*. Ketiga penyakit tersebut menyerang makula di Retina yang dapat menyebabkan kebutaan. Meskipun sekarang terdapat upaya pengobatan, laser, dan operasi namun hal tersebut tidak menjanjikan kembalinya tajam mata seperti semula.

Diagnosa penyakit mata pada retina dapat diperoleh dengan melakukan pengambilan data menggunakan alat *Optical Coherence Tomography* (OCT) lihat gambar 1.2. *Optical Coherence Tomography* (OCT) adalah teknik pencitraan yang menggunakan cahaya koheren untuk menangkap gambar resolusi tinggi dari jaringan biologis. OCT banyak digunakan oleh dokter mata untuk mendapatkan gambar retina mata beresolusi tinggi. Gambar OCT dapat digunakan untuk mendiagnosa banyak penyakit mata terkait retina. Diantaranya adalah *Choroidal Neovascularization*, *Diabetic Macular Edema* dan *Drusen* (Kermany dkk., 2018).



Gambar1.2 *Optical Coherence Tomography*

(<https://insightmedical.ca/product/zeiss-cirrus-4000-hd-oct/>)

OCT dapat mempermudah mendeteksi kelainan pada retina. OCT memberikan kontribusi besar pada perkembangan baru bidang optalmologi. OCT membantu para klinisi dalam menegakkan diagnosa, terutama pada situasi emergensi, untuk deteksi dini, mengikuti perjalanan penyakit dengan pemberian obat atau terapi laser (Novita dan Moestidjab, 2008).

Pengenalan pola pada citra OCT dapat diolah dengan menggunakan *neural network*. *Neural network* melakukan pemrosesan pada setiap piksel citra yang di olah. Model ANN yang terdiri atas berbagai lapisan yaitu *multi layer perceptron* (MLP). MLP berfungsi untuk mengklasifikasi, namun MLP memiliki kelemahan dalam mengklasifikasikan gambar. Pengembangan dari MLP adalah *Convolutional Neural Network* (CNN). CNN merupakan salah satu metode *deep learning* yang dapat digunakan untuk mendeteksi dan mengenali citra digital.

Deep learning merupakan salah satu implementasi dari *machine learning*. Arsitektur yang digunakan pada *deep learning* adalah MLP. Penelitian ini menggunakan proses pembelajaran *deep learning*, metode CNN dan *tensorflow* sebagai *library* pada *python*, dan akan menghasilkan suatu sistem untuk mengenali citra yang dihasilkan OCT. Data yang digunakan pada penelitian ini adalah penyakit pada retina mata yang diperoleh menggunakan alat OCT. OCT

akan mengambil gambar dengan 4 kondisi yaitu kondisi penyakit CNV, DME, Drusen, dan kondisi Normal.

Berdasarkan permasalahan tersebut dengan menggunakan teknologi pengenalan pola, muncul suatu gagasan untuk membuat sistem yang dapat mengenali pola citra yang dihasilkan oleh OCT. Sistem pengenalan pola citra ini sangat penting untuk dikaji para klinisi dalam mempercepat diagnosis sehingga dapat segera dilakukan tindakan selanjutnya.

1.2 Perumusan Masalah

Berdasarkan latar belakang yang telah diuraikan di atas, maka permasalahan yang akan dikaji adalah sebagai berikut.

- a. Bagaimana arsitektur jaringan yang optimal untuk *neural network* dalam mengenali pola citra CNV, DME, Drusen, dan Normal.
- b. Bagaimanakah sistem pengenalan pola citra OCT dapat mengenali kondisi retina mata normal ataupun penyakit CNV, DME, dan Drusen.
- c. Bagaimana mekanisme *training* data, dan *testing/evaluasi* data pada citra Normal, CNV, DME, dan Drusen.
- d. Berapa tingkat akurasi sistem dalam mengenali pola citra CNV, DME, Drusen, dan Normal.

1.3 Batasan Masalah

Penelitian ini menggunakan batasan sebagai berikut.

- a. Citra yang digunakan berupa gambar yang dihasilkan alat OCT dalam format .jpeg.
- b. Sistem hanya dirancang untuk mengenali 4 jenis gambar yang dihasilkan OCT yaitu CNV, DME, Drusen dan Normal.
- c. Data yang digunakan pada penelitian ini adalah data sekunder.
- d. Asumsi pengelompokan gambar retina mata hanya pada 3 jenis penyakit dan kondisi normal.
- e. Hasil pengelompokan hanya didasarkan pada sistem klasifikasi dengan komputer tanpa memperhatikan pertimbangan ahli penyakit mata.

1.4 Tujuan Penulisan

Berdasarkan rumusan masalah di atas, tujuan penelitian ini adalah sebagai berikut.

- a. Menentukan arsitektur jaringan yang optimal untuk *neural network* dalam mengenali pola citra CNV, DME, Drusen dan Normal.
- b. Merancang suatu sistem yang dapat mengenali citra CNV, DME, Drusen, dan Normal sebagai upaya membantu para klinisi mempercepat diagnosis sehingga dapat dilakukan tindakan selanjutnya.
- c. Mengetahui model *training* data dan *testing/evaluasi* data pada citra CNV, DME, Drusen dan Normal.
- d. Mengetahui tingkat akurasi sistem dalam mengenali pola citra CNV, DME, Drusen dan Normal.

1.5 Manfaat Penulisan

Manfaat dari penelitian ini adalah sebagai berikut.

(1) Manfaat Teoritis

Hasil penelitian ini diharapkan dapat memberikan sumbangan pemikiran dalam memperkaya wawasan konsep *statistical learning*, pengenalan pola gambar, *artificial neural network*, *deep learning*, dan CNN terutama tentang “Implementasi *deep learning* dalam digital *image processing* retina mata untuk deteksi kelainan pada makula”.

(2) Manfaat Praktis

Hasil penelitian ini diharapkan dapat menyumbangkan pemikiran terhadap pemecahan masalah yang berkaitan dengan “Implementasi *deep learning* dalam digital *image processing* retina mata untuk deteksi kelainan pada makula”. Selanjutnya hasil penelitian ini diharapkan menjadi acuan bagi penyusunan program pemecahan masalah pengenalan pola pada gambar diagnosa suatu penyakit.

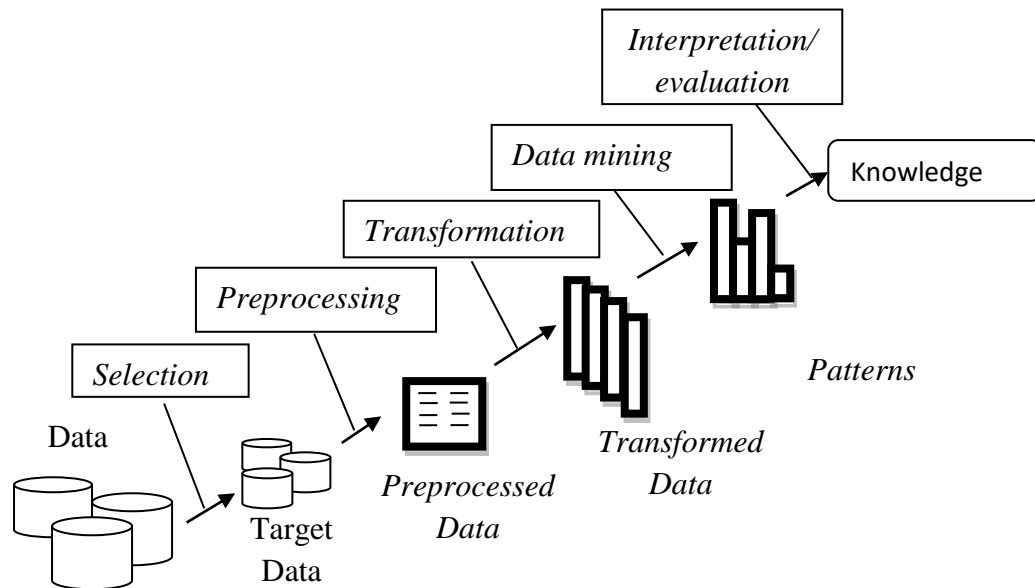
BAB II TINJAUAN PUSTAKA

2.1 Data Mining

Data Mining atau lebih dikenal dengan “*Knowledge Discovery in Database (KDD)*” menurut Jiawei dkk. (2012) merupakan salah satu cara yang digunakan untuk mendapatkan pengetahuan baru dengan memanfaatkan jumlah data yang sangat besar. Beberapa teknik telah dikembangkan dan di implementasikan untuk mengekstrak pengetahuan dan informasi untuk menemukan pola pengetahuan yang mungkin berguna untuk pengambilan keputusan. Teknik-teknik yang di gunakan dalam data mining adalah pengenalan pola, clustering, asosiasi, prediksi, dan klasifikasi .

Tahapan dari proses data mining adalah sebagai berikut.

1. *Data Selection*: merupakan pemilihan data dari sekumpulan data operasional. Data hasil seleksi akan digunakan untuk proses data mining dan disimpan dalam berkas terpisah dari data operasional.
2. *Pre-Processing/Cleaning*: proses menghapus duplikasi data, memeriksa data yang inkonsisten, dan memperbaiki kesalahan pada data. Proses ini juga dilakukan proses *enrichment* yaitu proses memperkaya data yang sudah ada dengan data atau informasi lain yang relevan.
3. *Transformation*: merupakan proses *coding*. Proses *coding* merupakan proses kreatif dan tergantung pada jenis atau pola informasi di *database*.
4. *Data Mining*: merupakan proses mencari pola atau informasi menarik dalam data dengan menggunakan teknik atau metode tertentu.
5. *Interpretation/Evaluation*: merupakan proses menampilkan pola informasi yang dihasilkan proses data mining. Tahap ini dilakukan pemeriksaan apakah pola atau informasi yang ditemukan bertentangan dengan fakta atau hipotesa yang ada sebelumnya.



Gambar 2.1 Tahapan proses KDD (Chung dkk., 2005)

Fungsi-fungsi dalam data mining ada 6 yang dapat digunakan yaitu sebagai berikut (Jiawei dkk., 2012).

a. Fungsi Deskripsi (*description*)

Fungsi deskripsi menggambarkan sekumpulan data secara ringkas. Memberikan gambaran secara ringkas bagi sekumpulan data yang besar jumlahnya dan berbagai macam.

b. Fungsi estimasi (*estimation*)

Fungsi estimasi merupakan fungsi untuk memperkirakan suatu hal yang sudah ada datanya. Fungsi estimasi terdiri atas dua cara yaitu: estimasi titik dan estimasi selang kepercayaan.

c. Fungsi Prediksi (*prediction*)

Fungsi prediksi memperkirakan hasil dari hal yang belum diketahui, atau mendapatkan hal baru, cara memprediksi dalam fungsi ini dapat menggunakan regresi linear.

d. Fungsi klasifikasi (*Classification*)

Fungsi klasifikasi atau menggolongkan suatu data, terdiri atas algoritma *Mean Vector*, algoritma *K-nearest neighbor*, algoritma ID3, algoritma C4.5, dan algoritma C5.0.

e. Fungsi pengelompokan (*Clustering*)

Fungsi pengelompokan data merupakan pengelompokan objek atau catatan yang memiliki kemiripan atribut kemudian dikelompokkan menjadi kelompok yang berbeda. Algoritma yang digunakan adalah algoritma *Hierarchical Clustering*, algoritma *partitional clustering*, algoritma *K-means* dan lain-lain.

f. Fungsi asosiasi (*association*)

Fungsi asosiasi digunakan untuk menemukan aturan asosiasi (*association rule*) yang mampu mengidentifikasi item-item yang menjadi objek. Algoritma yang digunakan adalah algoritma *Generalized Association Rules*, *Quantitative Association Rule*, *asynchronous Parallel Mining*,

2.2 Pembelajaran Statistika

Pembelajaran statistika (*statistical learning*) merupakan seperangkat alat untuk memodelkan dan memahami kumpulan data yang kompleks. *Statistical learning* merupakan area yang baru dikembangkan dalam statistik dan sejalan dengan perkembangan ilmu komputer khususnya *Machine Learning*. Banyaknya data yang tersedia saat ini, *statistical learning* menjadi ilmu pengetahuan yang memiliki peranan penting dalam menginterpretasikan data (James dkk., 2017).

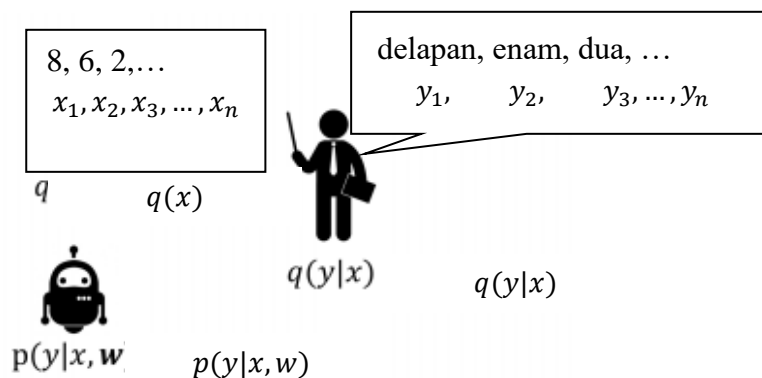
Pembelajaran statistik memiliki kontribusi penting dalam berbagai ilmu pengetahuan (Hastie dkk., 2017). Penelitian-penelitian tentang *statistical learning* diantaranya adalah penelitian yang dilakukan oleh Yaseen dkk. (2018) tentang peramalan pola hujan menggunakan novel *hybrid intelligent model* berdasarkan ANFIS-FFA, Makinen dkk. (2019) tentang peramalan *jump arrival* harga saham baru dengan *network architecture* menggunakan limit order data buku, dan Alom dkk. (2018) tentang *Recurrent residual convolutional neural network* berdasarkan U-Net (R2U-Net) untuk segmentasi gambar media.

Statistical learning sebagai alat yang digunakan untuk memahami data diklasifikasikan menjadi 3 yaitu *supervised learning*, *semi supervised learning*, dan *unsupervised learning* (James dkk., 2017).

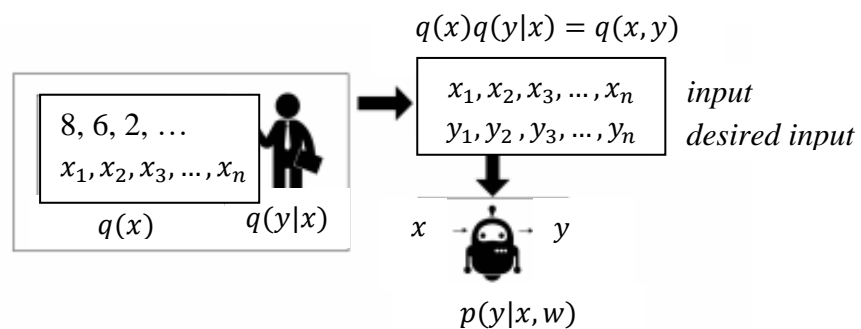
2.2.1 *Supervised Learning*

Supervised Learning atau dalam bahasa diterjemahkan sebagai pembelajaran terarah atau terawasi merupakan metode pembelajaran dengan data *training* bertindak sebagai panduan untuk menentukan model. Pembelajaran ini terdapat pemandu yang mengajari atau mengarahkan dan ada siswa yang menerima pelajaran. *User* berperan sebagai pemandu dan mesin berperan sebagai siswa. Persamaan *supervised learning* diinterpretasikan dalam persamaan berikut.

$$q(y|x) \tag{2.1}$$



Gambar 2.2 *Supervised learning-mathematical explanation*



Gambar 2.3 *Supervised learning – mathematical explanation 2*

(Sumber: Putra (2018))

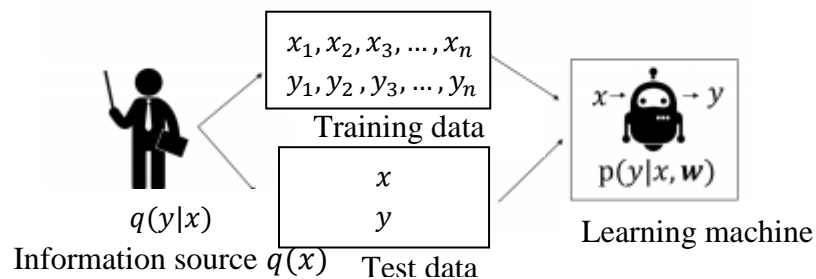
Gambar 2.2 dan gambar 2.3, x merupakan suatu kejadian (*event- random variable*). *Event-random variable* dinotasikan sebagai $\{x_1, x_2, x_3, \dots, x_n\}$ dengan x dapat berupa vektor, teks, gambar dan lain sebagainya. Fungsi distribusi probabilitas kondisional (*conditional probability density function*) $q(y|x)$ melambangkan hasil yang diharapkan untuk suatu kejadian.

Mesin mempelajari setiap pasangan *input-desired output* (*training data*) dengan mengoptimalkan *conditional probability density function* $p(y|x, w)$ dengan merupakan target (output), x adalah input dan vektor w adalah *learning parameters*. Proses belajar ini mengoptimalkan vektor w yang disebut sebagai *training*. Proses *training* bertujuan untuk mengaproksimasi $q(y|x)$ melalui $p(y|x, w)$.

Supervised learning memiliki tujuan secara umum yaitu untuk melakukan klasifikasi (*classification*). Model yang dibuat dapat dilakukan klasifikasi. Secara konseptual, klasifikasi didefinisikan sebagai persamaan 1.2 yaitu memilih label (kelas/kategori y) yang optimal dari himpunan label C , pada data tertentu.

$$\hat{y}_i = \underset{y_i \in C}{\operatorname{argmax}} p(y_i | x_i, w) \quad (2.2)$$

Model pada Gambar 2.4 memiliki panah ke *training* dan *test* data, yang artinya model hasil *training* bergantung pada data dan panduan. Model yang dihasilkan *training* (hasil pembelajaran kemampuan siswa) untuk data yang sama bisa berbeda untuk panduan yang berbeda.



Gambar 2.4 *Supervised learning framework*
(Sumber: Putra (2018))

Supervised learning memiliki 3 komponen penting yaitu *input*, *desired output*, dan *learning parameters*. *Learning parameters* berjumlah lebih dari satu, dan sering direpresentasikan dengan vektor atau matriks.

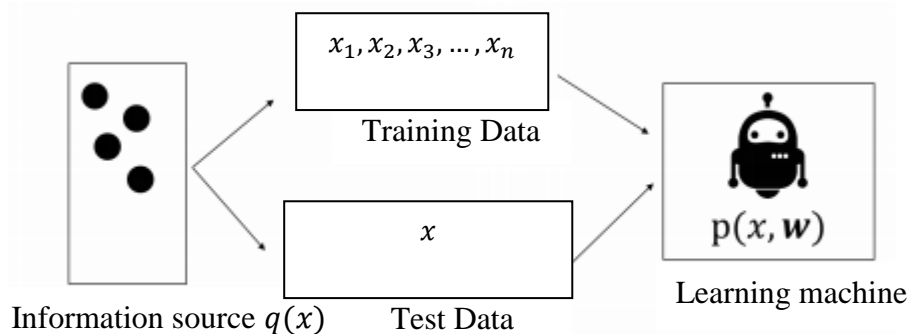
2.2.2 *Semi-supervised Learning*

Semi-supervised learning mirip dengan *supervised learning*. Perbedaan antara *supervised learning* dan *unsupervised learning* terletak pada proses pelabelan data. *Supervised learning* memiliki panduan yang harus membuat kunci jawaban *input-output* sedangkan *semi-supervised learning* tidak terdapat panduan

secara eksplisit. Kunci jawaban ini dapat diperoleh secara otomatis (misal dari hasil *clustering*). Umumnya kategori pembelajaran ini digunakan ketika data yang dimiliki hanya sedikit. Kemudian diciptakan data tambahan baik menggunakan *supervised* maupun *unsupervised learning*. Setelah didapatkan data yang cukup, dapat dibuat model pembelajaran dari data tambahan tersebut.

2.2.3 Unsupervised Learning

Berbeda dengan *supervised learning* dimana ada panduan yang mengajar, pada *unsupervised learning* tidak terdapat panduan. Contoh dalam permasalahan *unsupervised learning* adalah *clustering*. Pada *unsupervised learning* tidak ada *desired input* karena tidak ada panduan yang memberi contoh.



Gambar 2.5 Unsupervised learning framework

(Sumber: Putra (2018))

Learning dilakukan dengan mengoptimalkan fungsi $p(x|w)$ yang mengoptimasi parameter w . *Unsupervised learning* dapat diinterpretasikan dalam persamaan 2.3, dengan *input* dan parameter sebagai berikut.

$$p(x|w) \quad (2.3)$$

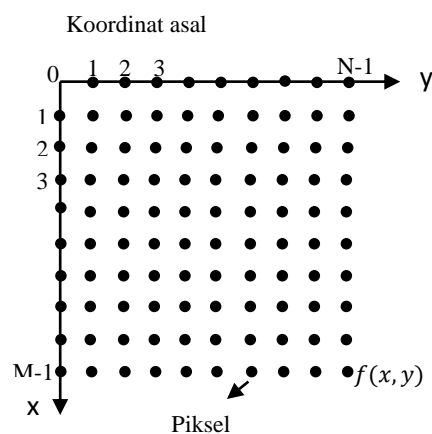
Unsupervised learning adalah pembelajaran untuk mencari sifat-sifat (*properties*) data. Aproksimasi $p(x|w)$ semirip mungkin dengan $q(x)$, dengan $q(x)$ adalah distribusi data yang asli.

2.3 Pengolahan Citra

Pengolahan citra adalah suatu proses pengolahan citra dengan menggunakan komputer menjadi sebuah citra yang memiliki kualitas yang lebih baik. Menurut Kamus Webster, pengenalan citra merupakan suatu representasi, kemiripan atau

imitasi dari suatu objek atau benda”. Ditinjau dari sudut pandang matematis, citra merupakan fungsi menerus (*continue*) dari intensitas cahaya pada bidang dwimatra. Sumber cahaya menerangi objek, objek memantulkan kembali sebagian dari berkas cahaya tersebut. Pantulan cahaya kemudian ditangkap oleh alat-alat optik seperti mata manusia, kamera, pemindai (*scanner*), dan lain-lain, sehingga bayangan objek yang disebut citra tersebut terekam(Munir, 2004).

Citra merupakan gambar pada bidang dua dimensi yang dihasilkan dari gambar analog dua dimensi dan kontinu menjadi gambar diskrit melalui proses sampling. Gambar analog dibagi menjadi M baris dan N kolom sehingga menjadi gambar diskrit(Richards dan Jia, 2005). Gambar 2.6 adalah koordinat citra digital terhadap sumbu (x, y) suatu bidang dua dimensi.



Gambar 2.6 Koordinat citra digital

Secara matematis citra digital dapat ditulis dalam bentuk matriks sebagai berikut.

$$f(x, y) = \begin{bmatrix} f(0,0) & f(0,1) & \cdots & f(0, N-1) \\ f(1,0) & f(1,1) & \cdots & f(1, N-1) \\ \vdots & \vdots & \ddots & \vdots \\ f(M-1, 0) & f(M-1, 1) & \cdots & f(M-1, N-1) \end{bmatrix} \quad (2.4)$$

Besar intensitas yang diterima sensor disetiap titik (x, y) disimbolkan oleh $f(x, y)$ dan besarnya tergantung pada intensitas yang dipantulkan oleh objek. $f(x, y)$ sebanding dengan energi yang dipancarkan oleh sumber cahaya, sehingga besar intensitas $f(x, y)$ adalah sebagai berikut(Suhendra, 2012).

$$0 < f(x, y) < \infty$$

fungsi $f(x, y)$ dapat dipisahkan menjadi dua komponen yaitu:

1. $i(x, y)$ adalah jumlah cahaya yang berasal dari sumbernya (*illumination*), dan
2. $r(x, y)$ adalah derajat kemampuan objek memantulkan cahaya (*reflection*).

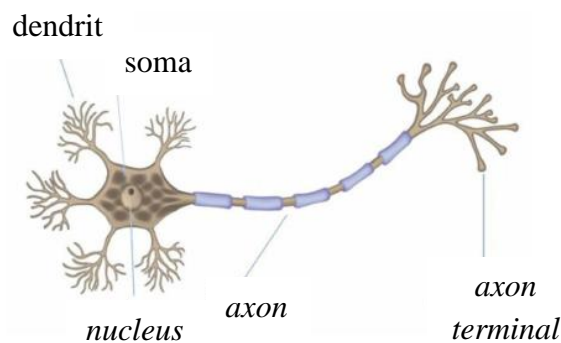
$$f(x, y) = i(x, y) \cdot r(x, y)$$

dengan $0 < i(x, y) < \infty$ dan $0 < r(x, y) < \infty$ (Suhendra, 2012).

Citra digital $a[m, n]$ yang dijelaskan dalam ruang diskrit 2D berasal dari gambar analog $a(x, y)$ dalam ruang kontinu 2D melalui proses pengambilan sampel yang sering disebut sebagai digitalisasi. Gambar kontinu 2D $a(x, y)$ dibagi menjadi M kolom dan N baris. Perpotongan baris dan kolom disebut piksel. Nilai yang diberikan kepada koordinat bilangan bulat $[m, n]$ dengan $\{m = 0, 1, 2, \dots, M - 1\}$ dan $\{n = 0, 1, 2, \dots, N - 1\}$ adalah $a[m, n]$. dalam kebanyakan kasus $a(x, y)$ merupakan fungsi dari banyak variabel seperti kedalaman (z), warna (λ), dan waktu (t).

2.4 Artificial Neural Network

Artificial Neural Network merupakan algoritma yang memiliki cara kerja sama seperti cara otak manusia bekerja. Otak manusia dapat memproses banyak informasi menggunakan data yang dikirim oleh indera manusia (terutama penglihatan). Pemrosesan dilakukan oleh *neuron*, yang bekerja pada sinyal listrik yang melewatinya dan menerapkan logika flip-flop, seperti membuka dan menutup gerbang agar sinyal dapat ditransmisikan seperti struktur gambar *neuron* sebagai berikut (Ciaburro dan Venkateswaran, 2017).




Gambar 2.7 Jaringan saraf
(Sumber: Ciaburro dan Venkateswaran (2017))

Artificial Neural network atau sering disebut jaringan saraf tiruan (JST) merupakan suatu sistem pemrosesan informasi yang menyerupai jaringan saraf

biologi (JSB). JST tercipta sebagai suatu generalisasi model matematis dari pemahaman manusia (*human cognition*) berdasarkan asumsi berikut.

- Pemrosesan informasi terjadi pada elemen sederhana yaitu *neuron*.
- Sinyal mengalir diantara sel saraf/*neuron* melalui suatu sambungan penghubung.
- Setiap sambungan penghubung memiliki bobot yang bersesuaian. Bobot ini akan digunakan untuk menggandakan atau mengalikan sinyal yang dikirim melalui *neuron*.
- Setiap sel saraf akan menerapkan fungsi aktivasi terhadap sinyal hasil penjumlahan berbobot yang masuk untuk menentukan sinyal output (Wuryandari dan Warsito, 2012).



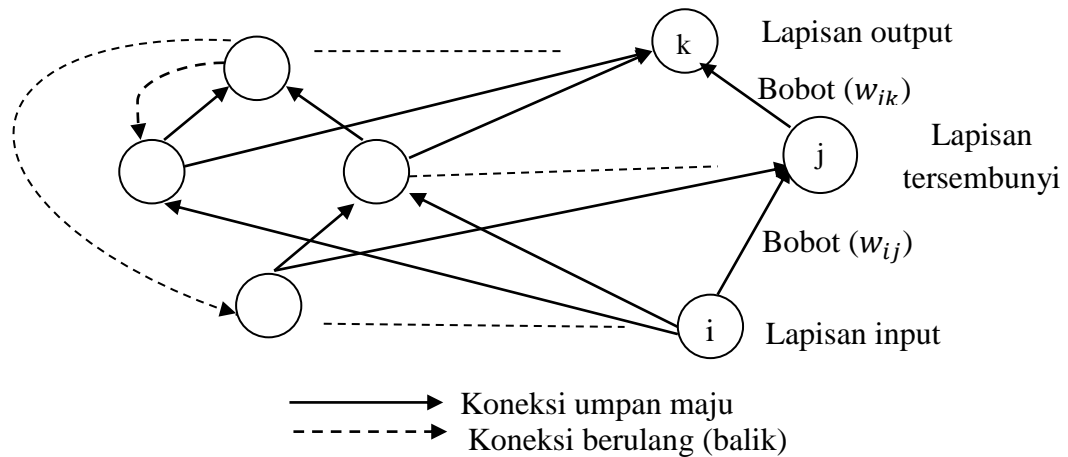
Gambar 2.8 Model struktur JST

(Sumber: Haykin (2014))

Artificial Neural Network terdiri atas beberapa *neuron*. Terdapat beberapa faktor yang menentukan sifat *neuron* yaitu bobot (*weight*) dan penggunaan fungsi aktivasi. Setiap lapisan pada *neuron* memiliki fungsi aktivasi yang sama. Lapisan-lapisan penyusun *neural network* dapat dibagi menjadi tiga (Jaya dkk., 2018).

- Input layer*: *node-node* di dalam *input layer* disebut unit-unit *input*. Unit-unit *input* menerima *input* dari luar. *Input* yang dimasukkan merupakan gambaran suatu masalah.
- Hidden layer*: *node-node* di dalam *hidden layer* disebut *node-node* tersembunyi. *Output* dari lapisan ini tidak dapat diamati secara langsung.

3. *Output layer: node-node pada output layer disebut unit-unit output. Output dari lapisan ini merupakan output neural network terhadap suatu permasalahan.*



Gambar 2.9 Arsitektur *Neural network*


(Sumber: Jaya dkk. (2018))

Gambar 2.9 merupakan salah satu contoh arsitektur *neural network multilayer* yang terdiri atas satu *layer input*, satu *hidden layer* dan 1 *output layer*. Arsitektur yang dapat dibentuk oleh *neural network* bermacam-macam. Arsitektur paling sederhana adalah ANN dengan satu *neuron (single neuron)* sampai yang paling rumit adalah multi *neuron (multiple neuron)* dalam satu lapis (*single layer*), dan jaringan *multiple neuron* dalam *multiple layers*. Semakin rumit suatu jaringan maka persoalan yang dapat diselesaikan menjadi semakin luas. Namun dalam proses *training* dan *testing* akan memerlukan waktu yang lama. Arsitektur *neural network* dibagi menjadi 3 yaitu *single perceptron*, *multilayer perceptron*, dan *competitive layer*. Penjelasan dari ketiga arsitektur *neural network* adalah sebagai berikut.

1. *Single Perceptron*

Single perceptron hanya terdiri atas sebuah *neuron*. Secara sistematis, terdapat *feature vector* yang menjadi *input* bagi *neuron*. *feature vector* mempresentasikan suatu data *point*, *events*, atau *instans*. *Neuron* akan memproses *input x* melalui perhitungan jumlah perkalian antara nilai *input* dan *synapse weight*. Pada *training*, nilai yang dioptimasi adalah nilai *synapse weight (learning*

parameter). Kemudian, nilai bias b sebagai kontrol tambahan. *Output* dari *neuron* adalah hasil fungsi aktivasi dari perhitungan jumlah perkalian antara nilai *input* dan *synapse weight* (Putra, 2018). Jaringan ini hanya menerima *input* kemudian secara langsung mengolahnya menjadi *output* tanpa harus melalui *hidden layer*.



Gambar 2.10 Single perceptron

(Sumber: Putra(2018))

Output pada *single perceptron* adalah $Output = activation_function(\sum_{i=1}^N x_i w_i + b)$


Sehingga dapat diperoleh

$$output = \begin{cases} -1 & \text{if } w \cdot x + b \leq 0 \\ 1 & \text{if } w \cdot x + b > 0 \end{cases}$$

dengan x_i adalah input, w_i adalah bobot, dan b adalah bias.

2. Multilayer perceptron (MLP)

Multilayer perceptron memiliki beberapa *layers*. Secara umum ada tiga *layers*: *input layer*, *hidden layer*, dan *output layer*. *Input layer* menerima *input* (tanpa melakukan operasi apapun), kemudian nilai *input* diberikan ke *hidden unit*. Proses pada *hidden unit*, *input* diproses dan dilakukan perhitungan hasil aktivasi untuk setiap *neuron*, hasilnya akan di lanjutkan ke layer berikutnya. *Output* dari *input layer* akan diterima sebagai *input hidden layer*. Seterusnya *output hidden layer* akan diteruskan ke *output layer*. Proses ini dinamakan *feed forward*. MLP merupakan gabungan dari beberapa fungsi non-linear.



Gambar 2.11 *Multilayer perceptron*
(Sumber: Ciaburro dan Venkateswaran(2017))


Setiap neuron i pada jaringan merupakan unit pemrosesan sederhana yang menghitung nilai aktivasi yaitu s_i terhadap input eksitasi atau input net_i . Persamaan net_i dapat ditunjukkan pada persamaan 2.5 sebagai berikut.

$$net_i = \sum_{j \in pred(i)} S_j w_{ij} - \theta_i \quad (2.5)$$

Dengan $pred_i$ adalah koneksi dari unit j ke unit i , w_{ij} adalah bobot koneksi, dan θ_i merupakan nilai bias dari i .

3. *Competitive layer*


Jaringan *Competitive layer* merupakan salah satu arsitektur jaringan yang terdiri atas sekumpulan *neuron* yang saling bersaing untuk mendapatkan hak menjadi aktif. *Competitive layer* merupakan salah satu bentuk dari *supervised learning neural network*, yang memiliki spesialisasi pada setiap node yang ada pada jaringan. *Competitive layer* biasanya diimplementasikan dengan *neural network* yang memiliki lapisan tersembunyi yang umumnya dikenal sebagai “lapisan kompetitif” dan Setiap neuron kompetitif dijelaskan oleh vektor bobot.



Gambar 2.12 Competitive Layer

2.5 Deep Neural Network

Deep Neural Network (DNN) merupakan *artificial neural network* yang memiliki banyak *layer*. Umumnya DNN memiliki lebih dari 3 *layers* yaitu *input layer*, *N hidden layers* dan *output layer*. Proses pembelajaran pada DNN disebut *deep learning* (Putra, 2018).

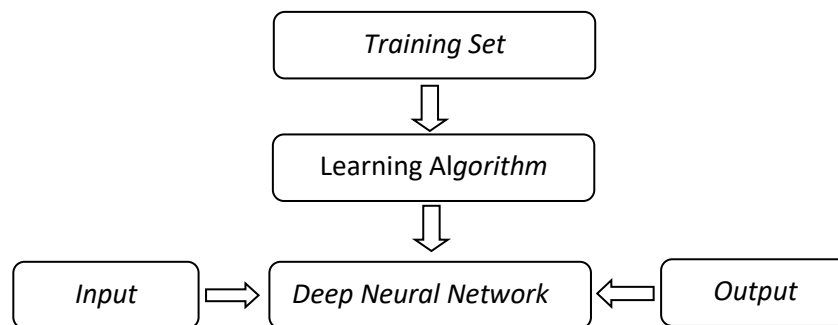


Gambar 2.13 Deep neural network

Gambar 2.13 merupakan DNN dengan 5 layer, sehingga final outputnya dapat dirumuskan sebagai berikut.

$$f_i = \sigma \left(\sum_{j=1}^{H_2} u_{j,i} \sigma \left(\sum_{k=1}^{H_1} v_{k,j} \sigma \left(\sum_{m=1}^M x_m w_{m,k} + \beta_k \right) + \gamma_j \right) + \lambda_i \right) \quad (2.5)$$

dengan β, γ, λ adalah noise atau bias (Putra, 2018). Secara garis besar alur kerja Deep Neural Network dapat digambarkan seperti Gambar 2.14 sebagai berikut.

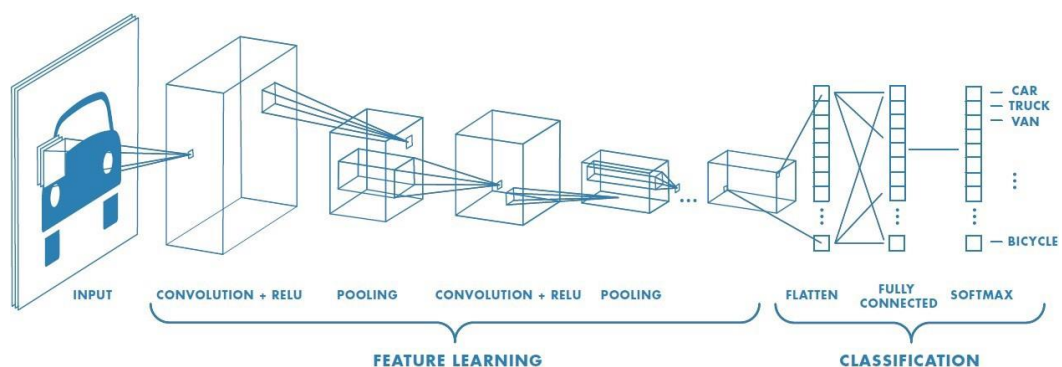


Gambar 2.14 Alur kerja *deep neural network*

(Sumber: Ciaburro dan Venkateswaran(2017))

2.6 Convolutional Neural Network

Convolutional neural network (CNN) merupakan arsitektur yang mampu mengenali informasi prediktif suatu objek seperti gambar, teks, potongan suara, dan lain sebagainya. CNN merupakan pengembangan dari *multilayer perceptron* (MLP) yang didesain untuk mengolah data dalam bentuk citra. CNN termasuk dalam jenis *Deep neural network* karena kedalaman jaringan yang tinggikan banyak diaplikasikan pada data citra. Penelitian tentang CNN pertama kali dilakukan oleh Hubel dan Wiesel (1968) tentang *visual cortex* pada indera penglihatan kucing. Arsitektur CNN terdiri atas beberapa layer yaitu *convolution layer*, fungsi *activation layer*, *pooling layer*, dan *fully connected layer*. Berikut adalah jaringan arsitektur *Convolutional Neural Network*.



Gambar 2.15 Arsitektur *Convolutional Neural Network*

Tahap pertama dalam arsitektur CNN adalah tahap konvolusi. Kemudian dilanjutkan fungsi aktivasi menggunakan fungsi aktivasi ReLu (*Rectifier Linear Unit*), kemudian dilanjutkan dengan proses *pooling*. Proses ini diulang terus

menerus sampai didapatkan peta fitur yang cukup untuk dilanjutkan ke *fully connected neural network*, sehingga dapat dihasilkan *output class*. Penjelasan secara detail dari tahap arsitektur CNN tersebut dijelaskan sebagai berikut.

2.6.1 Convolution Layer

Convolution layer merupakan proses utamayang mendasari jaringan arsitektur CNN dan terdiri atas kernel. Kernel-kernel pada lapisan ini sering disebut filter konvolusi. Kernel berfungsi mempelajari fitur-fitur lokal pada *feature map* (Khan dkk., 2018). Tahap *convolutional layer* melakukan operasi konvolusi pada *output* dari layer sebelumnya. Konvolusi adalah istilah matematis dimana pengaplikasian sebuah fungsi pada *output* fungsi lain secara berulang. Persamaan konvolusi merupakan persamaan pada dua fungsi argument bernilai riil. Operasi konvolusi $s(t)$ dapat ditunjukkan pada persamaan berikut.


$$s(t) = \sum_a I(a).K(t - a) \quad (2.10)$$

dengan $I(a)$ adalah input dan $K(a)$ adalah kernel. Input *convolution layer* merupakan gambar yang direpresentasikan menjadi sebuah matriks.

Operasi konvolusi menghasilkan nilai tinggi dan rendah pada posisi tertentu pada *feature map*. Posisi tertentu dari konvolusi kernel, merupakan perkalian untuk setiap nilai pada sel kernel dan nilai piksel gambar yang tumpang tindih dengan sel kernel (Ganegedara, 2018).

$$h_{i,j} = \sum_{k=1}^m \sum_{l=1}^m w_{k,l} x_{i+k-1,j+l-1} \quad (2.11)$$

dengan m adalah lebar dan tinggi kernel, h adalah *input convolution*, x adalah input, dan w adalah *convolutional kernel*. Sebagai contoh, ilustrasi pada proses *convolution layer* dengan nilai stride 2 adalah sebagai berikut.



Gambar 2.16 Ilustrasi *input convolution layer*
(Sumber: Khan dkk. (2018))

Perhitungan nilai pada *input convolution* diperoleh dengan menggunakan persamaan 2.11 yaitu sebagai berikut.

$$\begin{aligned}
 h_{1,1} &= (1.2) + (3.0) + (-2.-1) + (0.3) = 4 \\
 h_{1,2} &= (3.2) + (0.0) + (0.-1) + (3.3) = 15 \\
 h_{1,3} &= (0.2) + (-1.0) + (3.-1) + (2.3) = 3 \\
 h_{2,1} &= (-2.2) + (0.0) + (2.-1) + (-3.3) = -15 \\
 h_{2,2} &= (0.2) + (3.0) + (-3.-1) + (-1.3) = 0 \\
 h_{2,3} &= (3.2) + (2.0) + (-1.-1) + (4.3) = 19 \\
 h_{3,1} &= (2.2) + (-3.0) + (4.-1) + (2.3) = 6 \\
 h_{3,2} &= (-3.2) + (-1.0) + (2.-1) + (0.3) = -8 \\
 h_{3,3} &= (-1.2) + (4.0) + (0.-1) + (1.3) = 1
 \end{aligned}$$

Berdasarkan perhitungan di atas diperoleh *input convolution* sebagai berikut.

4	15	3
-15	0	19
6	-8	1

Gambar 2.17 *input convolution*

2.6.2 Fungsi Aktivasi

Fungsi aktivasi merupakan operasi matematik yang dikenakan pada sinyal *outputy*. Fungsi aktivasi berfungsi menentukan apakah suatu neuron aktif atau tidak berdasarkan *weighter sum* dari suatu input. Beberapa jenis fungsiaktivasi yang sering digunakan pada deep learning adalah sigmoid, Tanh, algebraic sigmoid, ReLU, noisy ReLU, Leakly ReLU/PReLU, *Randomized Leakly* ReLU, dan *Eksponential Linear Unit*(Khan dkk., 2018). Penelitian ini menggunakan 2 fungsi aktivasi yaitu fungsi aktivasi ReLU dan fungsi aktivasi *softmax*. Penjelasan dari kedua fungsi tersebut adalah sebagai berikut.


a. ReLU

Fungsi aktivasi *Rectifier Linear Unit*(ReLU)merupakan fungsi aktivasi sederhana yang memiliki kepentingan praktis khusus karena perhitungannya yang cepat.Kelebihan fungsi aktivasi ReLU dibandingkan denganfungsi aktivasi lain adalah sebagai berikut.

1. Fungsi aktivasi ReLU merupakan fungsi aktivasi *default* ketika mengembangkan multi layer perceptron dan *convolutional neural network*.
2. Fungsi aktivasi ReLU mengatasi masalah *gradient descent* yang hilang, yang memungkinkan model belajar lebih cepat dan berkinerja lebih baik.
3. Menemukan cara melatih jaringan dengan lebih cepat, sehingga mengurangi *overfitting*.

Fungsi aktivasi ReLU memetakan input ke 0 jika negatif dan mempertahankan nilainya jika positif. Representasi fungsi ReLU adalah sebagai berikut(Khan dkk., 2018).

$$f_{ReLU}(x) = \max(0, x) \quad (2.12)$$



Gambar 2.18 Fungsi aktivasi ReLU

(Sumber: Khan dkk. (2018))


b. Fungsi Aktivasi *Softmax*

Fungsi aktivasi *softmax* merupakan fungsi input vektor dari bilangan real K , yang kemudian dinormalkan menjadi distribusi probabilitas yang terdiri atas probabilitas K yang proporsional ke eksponensial input. Komponen vektor pada *softmax* memiliki interval $(0,1)$. Fungsi *softmax* merupakan lapisan yang menghubungkan antara *fully connected layer* dengan *dense connection*. *Softmax* berfungsi untuk menghitung probabilitas pada setiap kelas target yang memungkinkan dan akan membantu menentukan kelas target pada input yang diberikan. Nilai *softmax* berada pada rentang probabilitas *output* dari 0 hingga 1

dan jumlah semua probabilitas sama dengan satu. Definisi fungsi softmax $\sigma = \mathbb{R}^K \rightarrow \mathbb{R}^K$ adalah sebagai berikut.

$$\sigma(z)_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \tag{2.15}$$

dengan $i = 1, \dots, K$ dan $z = (z_1, \dots, z_K) \in \mathbb{R}^K$ (Khan, 2018). Sebagai contoh, ilustrasi fungsi aktivasi *softmax* dapat dilihat pada gambar 2.19 sebagai berikut.




Gambar 2.19 ilustrasi fungsi aktivasi softmax

Logits score menunjukkan lapisan neuron terakhir sebagai output mentah pada lapisan terakhir *neural network* sebelum proses aktivasi berlangsung. Setelah output diproses dengan softmax akan menghasilkan nilai probabilitas dengan jumlah 1.

2.6.3 Pooling Layer

Pooling layer terletak setelah *convolution layer*. *Pooling layer* terdiri atas sebuah filter dengan ukuran dan *stride* tertentu yang secara bergantian bergeser pada seluruh area *feature map*. Jenis *pooling layer* yang biasa digunakan yaitu *average pooling* dan *max pooling*. Nilai yang diambil pada *average pooling* adalah nilai rata-rata dan pada *max pooling* yang diambil adalah nilai maksimal. Lapisan *pooling* yang dimasukkan diantara lapisan konvolusi pada model CNN dapat mengurangi ukuran volume *output* pada *feature map*, sehingga mengurangi jumlah parameter dan perhitungan di jaringan.



Gambar 2.20 Operasi *max pooling* (Khan dkk., 2018)

Gambar 2.20 menggambarkan proses *max-pooling*. Output dari proses pooling adalah sebuah matriks dengan dimensi yang lebih kecil dibandingkan dengan citra awal.

Pooling layer beroperasi pada blok *input feature map* dan menggabungkan aktivasi fitur. Operasi kombinasi antara *pooling layer* dan fungsi aktivasi didefinisikan sebagai fungsi penyatuan seperti fungsi rata-rata atau maksimal.

2.6.4 Fully Connected Layer

Fully connected layer merupakan sebuah lapisan dimana semua *neuron* aktivasi dari lapisan sebelumnya terhubung dengan *neuron* lapisan selanjutnya. Perbedaan *fully connected layer* dengan konvolusi biasa adalah *neuron* pada lapisan konvolusi terhubung hanya ke daerah tertentu sedangkan *fully connected* memiliki *neuron* yang semuanya terhubung.

2.6.5 Hyperparameter


Hyperparameter merupakan variabel yang menentukan struktur jaringan dan variabel yang menentukan bagaimana jaringan dilatih. *Hyperparameter* ditetapkan sebelum *training* untuk mengoptimalkan bobot dan bias. Penelitian ini menggunakan 4 *hyperparameter* sebagai berikut.

1. *Epoch* merupakan proses iterasi pada dataset yang berulang setelah proses *training*.
2. *Stride* adalah nilai ukuran pergeseran yang digunakan untuk menggeser filter melalui input citra.
3. Data *training* merupakan data yang diujikan kepada program agar dapat mengenali pola input gambar yang memiliki kemiripan yang hampir sama atau mendekati citra sesungguhnya.
4. *Learning rate* adalah parameter yang menentukan seberapa cepat jaringan memperbaiki parameternya.

2.7 Identifikasi Penyakit Retina

Retina merupakan salah satu bagian mata yang mengandung reseptor penerima rangsangan cahaya. Retina berbentuk lapisan tipis di belakang mata.

Retina mengandung jutaan sel yang sensitif terhadap cahaya. Retina mata berfungsi sebagai film dan menyerap cahaya yang masuk ke mata, sehingga dapat meningkatkan kualitas penglihatan mata. Fungsi lainnya adalah menerima dan mengatur informasi visual pada otak melalui saraf optic (Septadina, 2015). Salah satu bagian dari jaringan saraf retina adalah makula.



Gambar 2.21 gambar retina normal

(<https://data.mendeley.com/datasets/rscbjbr9sj/2>)

Makula merupakan suatu area kecil pada lapisan bagian tengah retina mata dengan jumlah sel batang dan kerucut terbanyak. Makula memiliki peran penting untuk bisa melihat dengan baik pada saat terang maupun gelap dan membantu manusia waspada terhadap benda dan keadaan disekitarnya.


Kelainan pada Retina dapat menyebabkan kebutaan. Beberapa penyakit yang menyerang retina diantaranya adalah (1) Degenerasi Makula, (2) Lubang Makula, (3) *retinitis pigmentosa*, (4) ablasi retina, (5) retina robek, (6) *epiretinal membrane*, (7) *Choroidal neovascularization*, (8) *Drusen*. Diagnosis penyakit pada retina dapat dibuat berdasarkan pemeriksaan secara menyeluruh dengan USG, CT scan, MRI, *Optical coherence tomography* (OCT) tes amsler gris dan angiografi dengan zat kontras.

2.7.1 *Choroidal Neovascularization* (CNV)

Choroidal Neovascularization (CNV) merupakan kondisi pertumbuhan *invasif* pembuluh darah baru pada lapisan pembuluh darah tipis yang menyediakan makanan dan oksigen ke mata. Kehilangan penglihatan sentral terjadi ketika

pembuluh darah abnormal menyerang retina, jaringan peka cahaya yang melapisi permukaan dalam bola mata(Wu, 2019).

CNV paling sering ditemukan pada orang berusia 50 tahun keatas. Risiko tumbuh seiring dengan bertambahnya usia, dikarenakan sebagian besar CNV terkait dengan *age-related macular degeneration* (AMD). Diagnosis CNV dapat diperoleh dengan mengambil foto khusus mata menggunakan *fluorescein angiography* (FA) dan *optical coherence tomography* (OCT). FA menangkap gambar pembuluh darah retina saat zat pewarna menyoroti area abnormal, sedangkan pemindaian OCT membuat gambar penampang retina. Gambar 2.22 membantu mendeteksi pembuluh darah abnormal.




Gambar 2.22 Gambar CNV dengan menggunakan pemindaian OCT
(<https://data.mendeley.com/datasets/rscbjbr9sj/2>)

2.7.2 Diabetic Macular Edema (DME)

Diabetic Macular Edema (AMD) merupakan penyebab utama gangguan penglihatan pada orang dewasa di usia kerja. Meskipun cacat dalam fungsi *neurosensori* telah ditunjukkan pada pasien dengan diabetes mellitus sebelum timbulnya *vascular lesions*. Manifestasi awal klinis yang paling terlihat dari *retinopathy* meliputi pembentukan *mikrovaskular* menyebabkan *nonperfusi kapiler* retina, bintik kapas, peningkatan jumlah perdarahan, kelainan vena, dan kelainan *mikrovaskuler intraretinal* (IRMA). Selama tahap ini, peningkatan *vasopermeabilitas* dapat menyebabkan penebalan retina (*edema*) dan atau *eksudat*

yang dapat menyebabkan hilangnya ketajaman visual sentral (Emptage dkk., 2016).

Menurut penelitian yang dilakukan oleh Das (2016), *Diabetes mellitus* saat ini menggambarkan proporsi epidemik di dunia dan diperkirakan akan mempengaruhi 300 juta orang pada tahun 2025. Sebagai akibat dari *diabetes mellitus*, dalam jangka panjang dapat mengakibatkan munculnya komplikasi pada penglihatan penderita. Salah satu komplikasi dari *diabetes mellitus* adalah *Diabetic Macula Edema (DME)*. DME terjadi ketika cairan dan protein terkumpul pada atau dibawah makula mata, menghasilkan *edema* yang dapat merusak penglihatan sentral. Akibatnya tidak hanya dapat merusak penglihatan sentral tetapi juga bentuk dan warna ke arah pandangan.




Gambar 2.23 Gambar DME dengan menggunakan pemindaian OCT
(<https://data.mendeley.com/datasets/rscbjbr9sj/2>)

2.7.3 Drusen

Drusen retina adalah titik-titik kuning kecil dimata, terlihat antara lapisan retina terdalam atau terluar, yang disebut membran *Bruch*, dan *Retinal Pigment Epithelium (RPE)*. *Drusen* adalah penuaan yang ditandai dengan perubahan pada *atrofi* RPE dan hilangnya pigmen retina di berbagai tempat dan sering disebut sebagai *Age-related Macular Degeneration (AMD)*, kondisi progresif yang dapat menyebabkan hilangnya penglihatan sentral dan sebagian menyerang pasien usia lanjut (Williams dkk., 2009).

Menurut Porter(2018), Ada 2 jenis *drusen* yaitu (1) *Drusen* “Keras” berbentuk kecil, berbeda dan terletak jauh antara satu dengan yang lainnya. *Drusen* jenis ini tidak menyebabkan masalah penglihatan untuk waktu yang lama. (2) *Drusen* “lunak” dengan ciri-ciri berukuran besar dan lebih rapat satu dengan yang lainnya, tepinya tidak sejelas *drusen* “keras”. Jenis *drusen* ini meningkatkan resiko AMD. *Drusen* umumnya ditemukan pada orang berusia 60 atau lebih. Ras kaukasia lebih cenderung terkena penyakit ini, resiko *Drusen* meningkat pada orang yang keluarganya memiliki riwayat penyakit, merokok dan kadar kolestrol abnormal.



Gambar 2.24 Gambar *Drusen* dengan menggunakan pemindaian OCT

(<https://data.mendeley.com/datasets/rscbjbr9sj/2>)

2.8 Optical Coherence Tomography (OCT)

Optical Coherence Tomography (OCT) merupakan teknologi pencitraan yang menghasilkan gambaran resolusi mikron, *cross sectional*, pada jaringan *invivo*, dan mikrostruktur okuli. OCT dapat digunakan sebagai alat pemeriksaan penunjang untuk melakukandiagnosa. Karena kemudahannya dalam pemeriksaan mata, baik segmen *anterior* maupun *posterior*(Novita dan Moestidjab, 2018). OCTpertamakali digunakan pada aplikasiklinik tahun 1997. Penggunaan OCT dalam bidang optalmologi meningkat pesatterutama oleh spesialis retina. Selain itu OCT dapat dipakai untuk pemeriksaan kelainan glaukoma dan alat bantu pemeriksaan angiografi.Kelainan retina dapat dijelaskan oleh OCT seperti *edema makula*, *RPE detachment*, perubahan *neovascular intra-retinal*, serta *raksi vitreoretina*(Schuman, 2004).

Saat ini OCT digunakan dalam tiga bidang pencitraan optik, (1) Pencitraan makroskopik struktur yang dapat dilihat dengan mata telanjang atau menggunakan perbesaran lemah, (2) Pencitraan *mikroskopis* menggunakan perbesaran hingga batas klasik resolusi *mikroskopis* dan (3) Pencitraan *endoskopi*, menggunakan perbesaran rendah dan menengah (Fercher dkk., 2003).

OCT merupakan alat pemeriksaan *imaging* dengan prinsip kerja mirip dengan pemeriksaan *ultrasonografi B-mode* tetapi OCT lebih sensitif dan akurat. *ultrasonografi* memiliki resolusi 150 *mikron*. OCT memiliki resolusi 10 *mikron* untuk *time-domain* OCT (TD-OCT) dan 1-6 *mikron* untuk *spectral-domain* OCT (SD-OCT) (Perdana, 2014). OCT memberikan kontribusi besar pada perkembangan baru bidang optamologi. OCT membantu seorang klinisi dalam melakukan diagnosa pada situasi emergensi, untuk deteksi dini, dan mengikuti perjalanan penyakit dengan pemberian obat atau terapi laser (Novita dan Moestidjab, 2008).

2.9 Python


Python adalah bahasa pemrograman model skrip (*scripting language*) yang berorientasi obyek. *Python* merupakan bahasa pemrograman yang *freeware*, tidak ada batasan dalam penyalinannya atau mendistribusikannya lengkap dengan *source codenya*, *Debugger* dan *profiler*, fungsi sistem, GUI (antar muka penggunagrafis) dan basis datanya. *Python* memiliki beberapa fitur sebagai berikut (KPM, 2013).

- a. Memiliki kepustakaan yang luas, dalam distribusi *python* telah disediakan modul-modul.
- b. Memiliki tata bahasa yang mudah dipahami.
- c. Memiliki aturan layout kode sumber yang memudahkan pengecekan, pembacaan kembali dan penulisan ulang kode sumber.
- d. Berorientasi obyek.
- e. Dapat dibangun dengan bahasa *python* maupun C/C++.

Python digunakan untuk pengembangan perangkat lunak di perusahaan dan organisasi seperti Google, Yahoo, CERN, Industrial Light and Magic, dan NASA.

Pemrogram berpengalaman dapat mencapai hal-hal hebat dengan *python*. Kelebihan *python* adalah dapat diakses oleh programmer pemula dan memungkinkan untuk mengatasi masalah lebih cepat daripada menggunakan bahasa lain yang lebih kompleks (Halterman, 2011).

Python memiliki *package* dan *module*, *package* merupakan sekumpulan file-file *module*, sedangkan *module* adalah file-file yang berisi sekumpulan fungsi, *class* dan kode-kode *python*. *Module* dan *package* dalam *python* dapat digambarkan seperti Gambar 2.25 berikut (Hellmann, 2011).

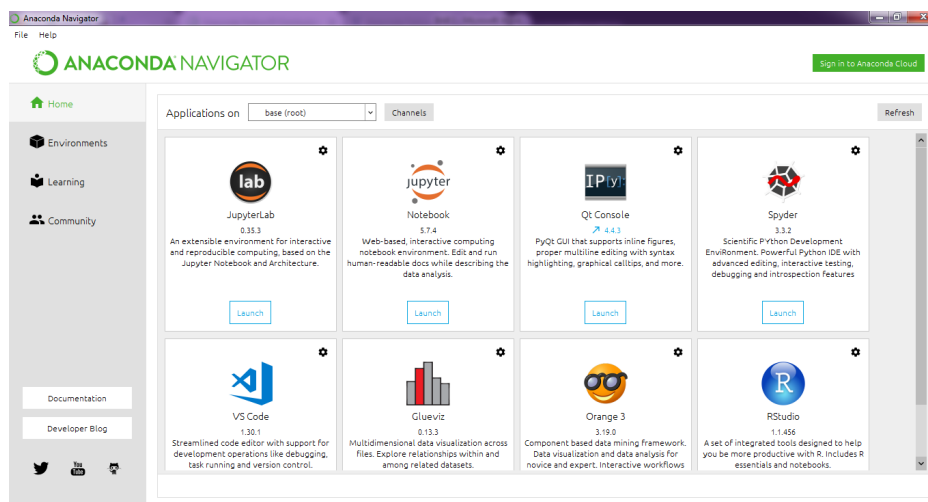


Gambar 2.25 Konsep *Module* dan *Package*

Konsep *module* dapat dijelaskan sebagai kode *python* yang akan digunakan secara berulang dan akan dipisahkan dari file utama ke dalam file khusus. *Module* mempunyai kode *python* yang *reuseable* agar kode yang ditulis pada program terduplikasi. *File python* kemudian akan dijalankan dan memanggil *function.class*, atau variabel. Kumpulan *module* yang dibuat berisir *runnable code*. Kode yang dieksekusi oleh *interpreter Python* untuk menampilkan wujud dari program yang dibuat (Hellmann, 2011).

2.9.1 Anaconda

Open source Anaconda adalah salah satu cara untuk mengolah data *science* dan *machine learning* pada *python* atau *R* di Linux, Windows dan Mac OS X (<https://www.anaconda.com/distribution/>).



Gambar 2.26 Tampilan *anaconda navigator*

Aplikasi *Anaconda* dilengkapi dengan *package* yang dibutuhkan dan mudah digunakan. Beberapa kelemahan menggunakan aplikasi asli dari *python* yaitu belum terinstalasinya berbagai *package* yang dibutuhkan dan tampilannya sedikit membosankan. Berbeda dengan *anaconda* yang telah dikembangkan, sudah dilengkapi berbagai *package* seperti *numpy*, *pandas*, *scipy*, *matplotlib*, *jupyter* dan beberapa *package* lain yang dapat diinstall.

2.9.2 *TensorFlow*

TensorFlow adalah perpustakaan (*library*) perangkat lunak pada *machine learning* yang berisi sistem untuk membangun dan melatih *deep neural network* mendeteksi dan menguraikan pola dan korelasi, dengan metode yang mirip dengan yang diadopsi oleh pembelajaran manusia. *Tensorflow* merupakan *framework* yang dimiliki oleh Google.

Node dalam grafik pada *TensorFlow* mewakili operasi matematika, sedangkan tepi grafik mewakili array data multidimensi (*tensor*) yang saling berkomunikasi. *TensorFlow* pada awalnya dikembangkan oleh Tim Google Brain dalam penelitian intelijen mesin Google untuk pembelajaran mesin (*machine learning*) dan penelitian *deep learning neural network*, tetapi sekarang tersedia dalam domain publik. *TensorFlow* mengeksplorasi pemrosesan GPU ketika dikonfigurasi dengan tepat (Ciaburro dan Venkateswaran, 2017). Penelitian yang

menggunakan *python* dan *tensorflow* adalah penelitian Santoso dkk. (2018), Afouras dkk. (2018), dan Makinen dkk. (2019).

2.10 Confusion Matrix

Pengukuran terhadap kinerja suatu sistem klasifikasi merupakan hal yang penting. Kinerja sistem klasifikasi menggambarkan seberapa baik sistem mengklasifikasikan data. *Confusion matrix* adalah salah satu metode yang dapat mengukur kinerja suatu metode klasifikasi (Ciaburro dan Venkateswaran, 2017).

Pengukuran kinerja *Confusion matrix* memiliki 4 istilah representasi hasil proses klasifikasi yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN).

Kelas	Terklasifikasi Positif	Terklasifikasi negatif
Positif	TP	FN
Negatif	FP	TN

Tabel 2.1 *Confusion matrix* pada *binary* klasifikasi

Nilai akurasi menggambarkan akurasi sistem dalam mengklasifikasi gambar secara benar. Nilai akurasi dapat diperoleh dari perbandingan antara data yang terklasifikasi benar dengan keseluruhan data.

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (2.15)$$

Persamaan 2.15 merupakan rumus akurasi untuk *binary classification*. Klasifikasi dengan kelas lebih dari 2 atau *multi class* dari persamaan 2.15 dapat diubah menjadi persamaan 2.15 sebagai berikut.

$$Akurasi = \frac{\sum_{i=1}^l \frac{TP_i + TN_i}{TP_i + TN_i + FP_i + FN_i}}{l} \times 100\% \quad (2.16)$$

dengan

TP_i adalah *True Positive* yaitu jumlah data positif yang terklasifikasi dengan benar oleh sistem untuk kelas ke- i

TN_i adalah *True Negative* yaitu jumlah data negatif yang terklasifikasi dengan benar oleh sistem untuk kelas ke-i

FN_i adalah *False Negative* yaitu jumlah data negatif namun terklasifikasi salah oleh sistem untuk kelas ke-i

FP_i adalah *False Positive* yaitu jumlah data positif namun terklasifikasi salah oleh sistem untuk kelas ke-i

l adalah jumlah kelas klasifikasi.


Selain nilai akurasi, terdapat nilai *loss function* yang merupakan salah satu nilai yang dapat digunakan untuk mengukur sistem yang dibuat. *Loss function* mengkuantifikasi perbedaan antara estimasi output model prediksi dengan output model yang sebenarnya. Penelitian ini menggunakan *cross entropy loss* dengan persamaan sebagai berikut.

$$L(p, y) = - \sum_R y_n \log(p_n), n \in [1, N] \quad (2.17)$$

y merupakan output, p adalah probabilitas untuk setiap kategori output, N adalah semua neuron pada lapisan output, sedemikian sehingga $p, y \in \mathbb{R}^N$. Probabilitas masing-masing kelas dapat dihitung dengan menggunakan fungsi aktivasi softmax $p_n = \frac{\exp(\hat{p}_n)}{\sum_k \exp(\hat{p}_k)}$, dengan \hat{p}_n merupakan nilai output yang tidak dinormalkan dari lapisan sebelumnya dalam jaringan (Khan dkk., 2018).

2.11 Penelitian Terdahulu

Penelitian Kermany dkk.(2018) tentang “*Identifying Medical Diagnoses and Treatable Disease by Image-Based Deep Learning*” diperoleh perbandingan multi kelas antara CNV, DME, Drusen dan Normal mencapai akurasi 96,6% dengan sensitivitas 97,8%, spesifitas 97,4 dan kesalahan 6,6%.

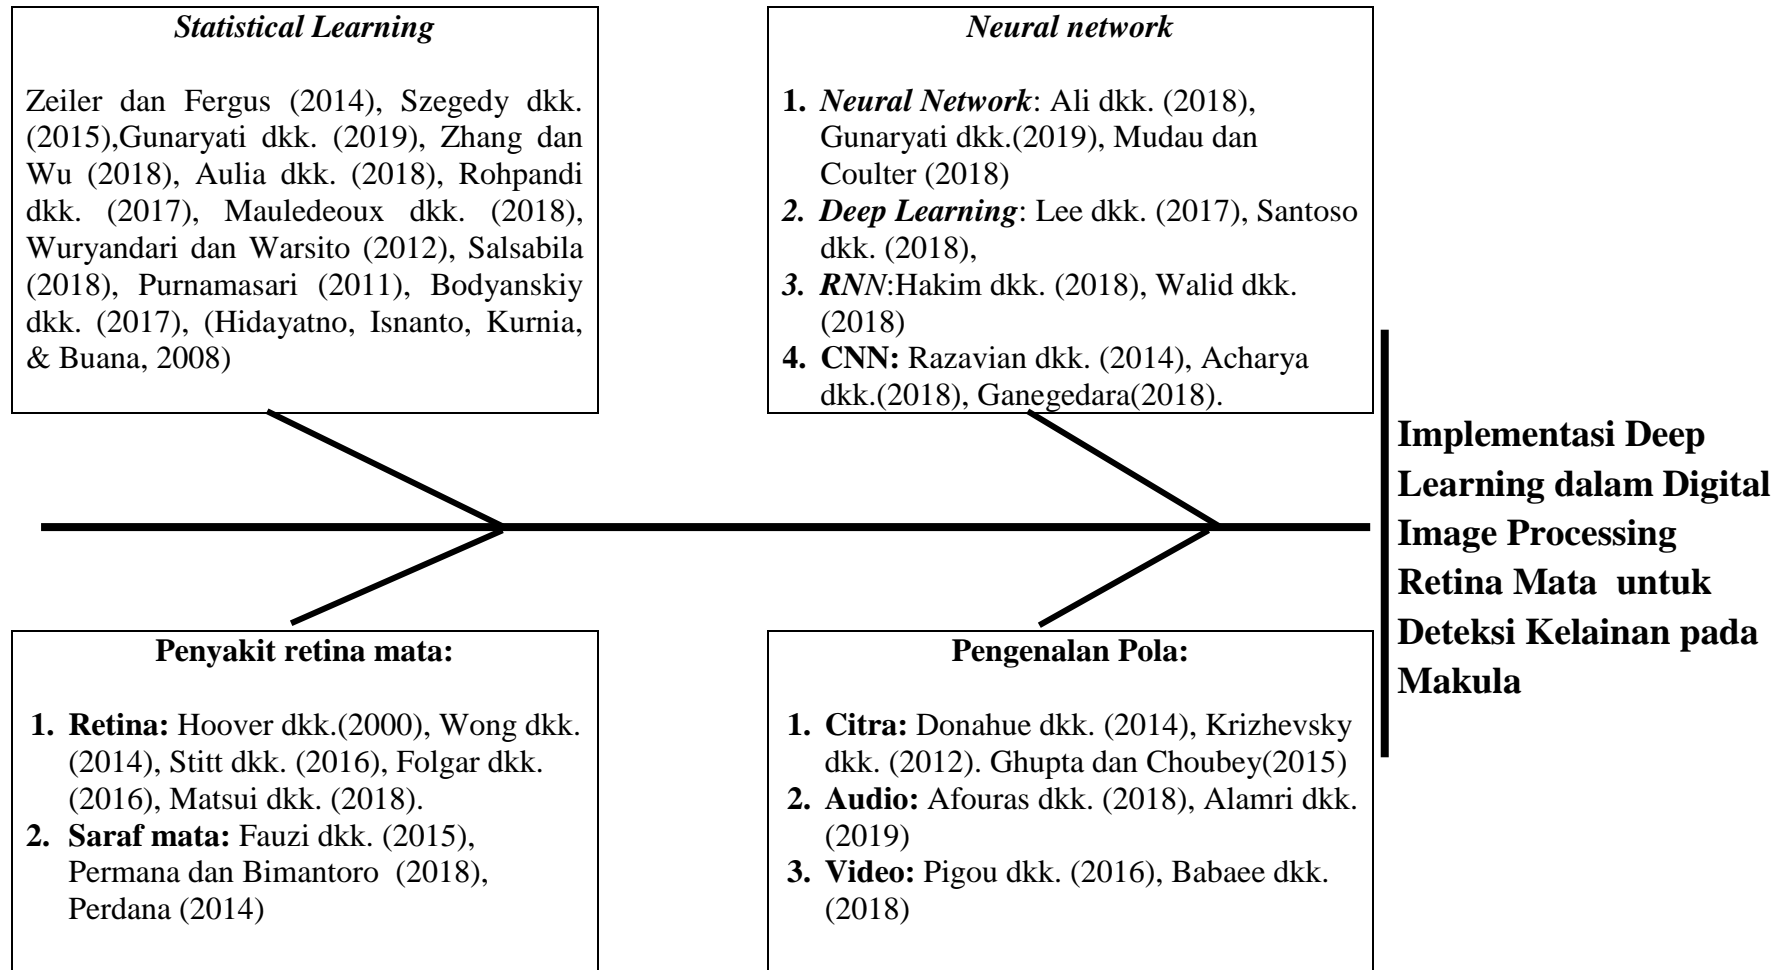


Gambar 2.27 Tabel prediksi dan error

(Sumber: Kermany dkk. (2018))

Penelitian Liang dkk.(2016) tentang analisis gambar berbasis CNN untuk diagnosis Malaria. Malaria merupakan ancaman kesehatan dunia. Cara standar untuk mendiagnosis malaria adalah dengan memeriksa secara visual blood smears pada sel darah merah yang terinfeksi parasit menggunakan mikroskop yang dilakukan oleh teknisi ahli. Penelitian ini menggunakan model CNN untuk mengklasifikasikan sel tunggal dalam blood smears pada slide mikroskop standar untuk mendeteksi terinfeksi atau tidak terinfeksi. Berdasarkan 27.578 gambar sel tunggal, akurasi rata-rata model CNN adalah 97,37%.

Penelitian terkait lainnya dijelaskan dalam gambar 2.29 berikut.



Gambar 2.28 Penelitian Terdahulu

BAB V

KESIMPULAN DAN SARAN

5.2 Kesimpulan

Berdasarkan hasil analisis yang telah dilakukan, diperoleh kesimpulan sebagai berikut.

1. Penelitian ini menggunakan arsitektur jaringan CNN dengan input *feature shape* berukuran 8x8, nilai *learning rate* 0.001, ukuran kernel 2048x2048, jumlah *epoch* 50, data *training* 83484, dan data *testing* 1000.
2. Sistem pengenalan pola memiliki 3 tahapan proses yaitu *extract features*, *training* data, dan proses *evaluate*.
3. Mekanisme *training* data dan evaluasi terdiri atas beberapa parameter. Beberapa parameter dilakukan percobaan dengan metode *trial* dan *error* didapatkan hasil sebagai berikut.
 - a. Tingkat akurasi terbaik pada parameter *epoch* adalah 50 *epoch* dengan tingkat akurasi tertinggi 0,99 dan nilai *loss* validasi terendah yaitu 0,2034. Banyaknya *epoch* belum tentu menghasilkan nilai akurasi yang tinggi, sehingga perlu dilakukan beberap kali proses untuk menemukan nilai akurasi yang optimal.
 - b. Tingkat akurasi terbaik pada parameter *stride* adalah 1 dengan tingkat akurasi tertinggi 0,99 dan nilai *loss* validasi terendah yaitu 0,2267. *stride* yang relative kecil akan membaca gambar dengan lebih teliti dibanding dengan menggunakan *stride* yang lebih besar.
 - c. Tingkat akurasi terbaik pada parameter data *train* adalah data sebanyak 83483 dengan tingkat akurasi tertinggi 0,99 dan nilai *loss* validasi 0,2524. Penggunaan data *train* yang banyak dapat melatih sistem untuk dapat mempelajari setiap pola pada setiap gambar. Semakin banyak sistem belajar, maka tingkat akurasi yang dihasilkan semakin tinggi.
 - d. Tingkat akurasi terbaik pada parameter nilai *learning rate* adalah 0.0001 dengan tingkat akurasi tertinggi 0,992 dengan nilai *loss* validasi

terendah yaitu 0,2524. Nilai *learning rate* yang relatif kecil akan menghasilkan ketelitian jaringan yang besar.

- e. Parameter banyak data *train* merupakan parameter yang paling banyak mempengaruhi nilai akurasi. Hal ini disebabkan, semakin banyak data yang digunakan, maka sistem akan lebih mudah memprediksi gambar dengan baik.
4. Hasil testing dengan menggunakan model 'model.features.47-0.99.hdf5' menghasilkan nilai akurasi 99,2%.

5.2 Saran

Saran yang diberikan pada penelitian ini adalah sebagai berikut.

1. Penelitian selanjutnya dapat menambahkan parameter seperti nilai *dropout*, fungsi aktivasi, penggunaan *optimizer*, sehingga dapat menghasilkan model yang optimal.
2. Penelitian selanjutnya dapat menggunakan data primer pada proses *evaluate*, dengan data yang diperoleh dari rumah sakit di Indonesia.
3. Penelitian selanjutnya dapat dikembangkan kedalam aplikasi pada smartphone, yang dapat membaca gambar yang dihasilkan oleh OCT.

DAFTAR PUSTAKA

- Acharya, U. R., Oh, S. L., Hagiwara, Y., Tan, J. H., & Adeli, H. (2018). Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals. *Computers in Biology and Medicine*, *100*, 270–278.
- Afouras, T., Chung, J. S., Senior, A., Vinyals, O., & Zisserman, A. (2018). Deep Audio-visual Speech Recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, *PP(c)*, 1.
- Alamri, H., Cartillier, V., Das, A., Wang, J., Cherian, A., Essa, I., Parikh, D. dkk. (2019). Audio Visual Scene-Aware Dialog. *IEEE Xplore*, 7558–7567.
- Ali, I., Alharbi, O. M. L., Alothman, Z. A., Badjah, A. Y., Alwarthan, A., & Basheer, A. A. (2018). Artificial Neural Network Modelling of Amido Black Dye Sorption on Iron Composite Nano Material: Kinetics and Thermodynamics Studies. *Journal of Molecular Liquids*, *250*, 1–8.
- Alom, M. Z., Hasan, M., Yakopcic, C., Taha, T. M., & Asari, V. K. (2018). Recurrent Residual Convolutional Neural Network based on U-Net (R2U-Net) for Medical Image Segmentation. *Computer Science and Pattern Recognition*, *5*, 1–12.
- Aulia, N. N., Gunawan, P. H., & Rohmawati, A. A. (2018). Prediksi Curah Hujan Harian Menggunakan Gerak Brown dan Rataan Tahunan Data Pada Missing Values. *Indonesian Journal on Computing (Indo-JC)*, *3*, 38–44.
- B, M. R., Ordonez, V., & Redmon, J. (2016). XNOR-Net: ImageNet Classification Using Binary Convolutional Neural Networks. In B. Leibe, J. Matas, N. Sebe, & M. Welling (Eds.), *Computer Vision and Pattern Recognition* (Vol. 9908, pp. 525–542). Cham: Springer International Publishing.
- Babae, M., Dinh, D. T., & Rigoll, G. (2018). A deep convolutional neural network for video sequence background subtraction. *Pattern Recognition*, *76*, 635–649.

- Bodyanskiy, Y. V., Tyshchenko, O. K., Hu, Z., & Tkachov, V. M. (2017). Fuzzy Clustering Data Arrays with Omitted Observations. *International Journal of Intelligent Systems and Applications*, 9(6), 24–32.
- Chung, H. M., Gray, P., & Mannino, M. (2005). *Introduction to Data Mining and Knowledge Discovery*. Potomac: Two Crows Corporation.
- Ciaburro, G., & Venkateswaran, B. (2017). *Neural Networks with R* (Vol. 6). Birmingham: Packt Publishing Ltd.
- Coudray, N., Ocampo, P. S., Sakellaropoulos, T., Narula, N., Snuderl, M., Fenyő, D., ... Tsirigos, A. (2018). Classification and mutation prediction from non-small cell lung cancer histopathology images using deep learning. *Nature Medicine*, 24(10), 1559–1567.
- Das, U. N. (2016). Diabetic macular edema, retinopathy and age-related macular degeneration as inflammatory conditions. *Archives of Medical Science*, 12(5), 1142–1157.
- Donahue, J., Jia, Y., Vinyals, O., Hoffman, J., Zhang, N., Tzeng, E., Edu, B. dkk. (2014). DeCAF: A Deep Convolutional Activation Feature for Generic Visual Recognition. *Computer Science and Pattern Recognition*, 32, 1–5.
- Emptage, N. P., Kealey, S., Lum, F. C., & Garratt, S. (2016). AAO Guidelines for Diabetic Retinopathy.
- Fauzi, H., Hadi, F., Telekomunikasi, J. T., Elektro, F. T., & Telkom, U. (2015). Glaucoma Detection System on High Resolution. *Jurnal Elektro Telekomunikasi Terapan*, 188–194.
- Fercher, A. F., Drexler, W., Hitzenberger, C. K., & Lasser, T. (2003). Optical coherence tomography - Principles and applications. *Rep.Prog.Phys*, 66(2), 239–303.
- Folgar, F. A., Yuan, E. L., Sevilla, M. B., Chiu, S. J., Farsiu, S., Chew, E. Y., & Toth, C. A. (2016). Drusen Volume and Retinal Pigment Epithelium Abnormal Thinning Volume Predict 2-Year Progression of Age-Related Macular Degeneration. *Ophthalmology*, 123(1), 39-50.e1.
- Gunaryati, A., Andryana, S., & Kasyfi, F. (2019). Perbandingan Metode Peramalan Eksponensial Smoothing dan Metode Jaringan Syaraf Tiruan

- Propagasi Balik untuk Data Pengguna Pita Lebar (Broadband) di Indonesia. *Jurnal Sistem Informasi, Teknologi Informatika Dan Komputer*, 8(February), 81-.
- Gupta, D., & Choubey, S. (2015). Discrete Wavelet Transform for Image Processing. *International Journal of Emerging Technology and Advanced Engineering (IJETAE)*, 4(3), 598–602.
- Hakim, L. A., Osmond, A. B., & Saputra, R. E. (2018). Recurrent Neural Network untuk Penenalan Ucapan Pada Bahasa Sunda Selatan Dialek Garut. *E-Proceeding of Engineering*, 5(3), 6431–6435.
- Harahap, J., & Andayani, L. S. (2018). Pola Penyakit Degeneratif, Tingkat Kepuasan Kesehatan dan Kualitas Hidup pada Lansia (Lanjut Usia) di Kota Medan. *Talenta Conference Series: Tropical Medicine (TM)*, 1(1), 142–149.
- Hastie, T., Tibshirani, R., & Friedman, J. (2017). *The Elements of Statistical Learning The Elements of Statistical Learning*. Stanford: Springer.
- Haykin, S. (2014). *Neural Networks A Comprehensive Foundation Second Edition*. Prentice Hall International, Inc.
- Hellmann, D. (2011). *The Python Standard Library by Example*. Boston: Pearson Education .Inc.
- Hidayatno, A., Isnanto, R. R., Kurnia, D., & Buana, W. (2008). Identifikasi Tanda-Tangan Menggunakan Jaringan Saraf Tiruan Perambatan-Balik (Bakpropagation). *Jurnal Teknologi*, 100–106.
- Hoover, A., Kouznetsova, V., & Goldbaum, M. (2000). Locating Blood Vessels in Retinal Images by Piece-wise Threshold Probing of a Matched Filter Response Department of Ophthalmology University of California , San Diego. *IEEE Transactions on Medical Imaging*, 19(3), 203–210.
- Hubel, D. H., & Wiesel, T. N. (1968). Receptive Fields And Functional Architecture of Monkey Striate Cortex. *The Journal of Phisiology*, 195, 215–243.
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2017). *An Introduction to Statistical Learning. An Introduction to Statistical Learning: with Applications in R*. London: Springer.

- Jan Wira Gotama Putra. (2018). *Pengenalan Pembelajaran Mesin dan Deep Learning*. Tokyo: <https://www.researchgate.net/publication/323700644>.
- Jaya, H., Sabran, Idris, muh ma'ruf, Djawad, yasser A., Ilham, & Ahmar, A. S. (2018). *Kecerdasan Buatan*. Makasar: Fakultas MIPA Universitas Negeri Makasar.
- Jiawei, H., Micheline, K., & Jian, P. (2012). *Dm Concepts and Techniques Preface and Introduction*. Urbana: Elsevier Inc.
- Kermany, D. S., Baxter, S. L., Duan, Y., Zhang, C. L., Lewis, M. A., Singer, M. A., Xia, H. dkk. (2018). Identifying Medical Diagnoses and Treatable Diseases by Image-Based Deep Learning. *Cell*, 172(5), 1122-1131.e9.
- Khan, S., Rahmani, H., Afaq, S., Shah, A., & Bennamoun, M. (2018). *A Guide to Convolutional Neural Networks for Computer Vision*. (G. Medioni & S. Dickinson, Eds.). California: Morgan & Claypool Publishers series.
- KPM. (2013). *Buku Panduan Pemrograman Python* (Vol. 84). Pernalang: Pemerintah Kabupaten Pernalang.
- Kriesel, D. (2005). *A Brief Introduction to Neural Networks*. Germany: www.dkriesel.com.
- Krizhevsky, B. A., Sutskever, I., & Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Research Highlight*, 60, 84–90.
- Lantz, B. (2017). *Machine Learning with R*. Singapore: Springer Singapore.
- Lee, C. S., Baughman, D. M., & Lee, A. Y. (2017). Deep Learning Is Effective for Classifying Normal versus Age-Related Macular Degeneration OCT Images. *Kidney International Reports*, 2(4), 322–327.
- Liang, Z., Powell, A., Ersoy, I., Poostchi, M., Silamut, K., Palaniappan, K., Thoma, G. dkk. (2016). CNN-Based Image Analysis for Malaria Diagnosis. *IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, 493–496.
- Lu, H., Li, Y., Chen, M., Kim, H., & Serikawa, S. (2018). Brain Intelligence: Go beyond Artificial Intelligence. *Mobile Networks and Applications*, 23(2), 368–375.

- Mäkinen, Y., Kanninen, J., Gabbouj, M., & Iosifidis, A. (2019). Forecasting jump arrivals in stock prices: new attention-based network architecture using limit order book data. *Quantitative Finance*, 7688, 1–18.
- Mauledoux, M., Hernandez, R. D., Jimenez, R., Ortiz, N., & Aviles, O. (2018). Survey of biometric pattern recognition via machine learning techniques. *Contemporary Engineering Sciences*, 11(34), 1677–1694.
- Michael F. Land, & Fernald, R. D. (1997). The Evolution of Eyes. *Brain, Behavior and Evolution*, 50(4), 253–259.
- Mudau, T., & Coulter, D. (2018). ANN-MIND: A Comparative Study on the Training of Neural Networks with Incomplete Datasets. *2018 IST-Africa Week Conference (IST-Africa)*, Page 1 of 8-Page 8 of 8.
- Munir, R. (2004). *Pengolahan Citra Digital dengan Pendekatan Algoritma*. Bandung: Informatika ITB.
- Novita, H. D., & Moestidjab. (2008). Optical Coherence Tomography Posterior Segment. *Jurnal Oftalmologi Indonesia*, 6(3), 160–177.
- Novita, H. D., & Moestidjab. (2018). Optical Coherence Tomography Optical Coherence Tomography (OCT). *Jurnal Oftalmologi Indonesia*, 6(February), 169–177.
- Ohno-Matsui, K., Ikuno, Y., Lai, T. Y. Y., & Gemmy Cheung, C. M. (2018). Diagnosis and treatment guideline for myopic choroidal neovascularization due to pathologic myopia. *Progress in Retinal and Eye Research*, 63(October 2017), 92–106.
- Perdana, O. P. (2014). *Perubahan Ketebalan Lapisan Serabut Saraf Peripapil Pada Pasien Glaukoma Kronik Dan Glaukoma Pasca Fakoemulsifikasi Menggunakan Optical Coherence Tomography*. Univesitas Indonesia.
- Permana, Y., Wijaya, I. G. P. S., & Bimantoro, F. (2018). Sistem Pakar Diagnosa Penyakit Mata Menggunakan Metode Certainty Factor Berbasis Android. *Journal of Computer Science and Informatics Engineering (J-Cosine)*, 1(1), 1.
- Pigou, L., Oord, A. Van Den, Dieleman, S., Herreweghe, M. Van, & Dambre, J. (2016). Beyond Temporal Pooling : Recurrence and Temporal Convolutions

- for Gesture Recognition in Video. *International Journal of Computer Vision*.
- Razavian, A. S., Azizpour, H., Sullivan, J., & Carlsson, S. (2014). CNN features off-the-shelf: An astounding baseline for recognition. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*, 512–519.
- Richards, J. A., & Jia, X. (2005). *Remote Sensing Digital Image Analysis*. Berlin, Germany: Springer-Verlag. German: Springer.
- Rohpandi, D., Sugiharto, A., & Jati, M. Y. S. (2017). Klasifikasi Citra Digital Berbasis Ekstraksi Ciri Berdasarkan Tekstur Menggunakan GLCM Dengan Algoritma K-Nearest Neighbor, 79–86.
- Salsabila. (2018). *Penerapan Deep Learning Menggunakan Convolution Neural Network untuk Klasifikasi Citra Wayang Punakawan*. Universitas Islam Indonesia.
- Santoso, Aditya and Ariyanto, G. (2018). Implementasi Deep Learning Berbasis Keras Untuk Pengenalan Wajah. *Emitor: Jurnal Teknik Elektro*, 18(01), 15–21.
- Septadina, I. S. (2015). Perubahan Anatomi Bola Mata pada Penderita Diabetes Mellitus, (2), 139–143.
- Stitt, A. W., Curtis, T. M., Chen, M., Medina, R. J., McKay, G. J., Jenkins, A., ... Lois, N. (2016). The progress in understanding and treatment of diabetic retinopathy. *Progress in Retinal and Eye Research*, 51, 156–186.
- Suhendra, A. (2012). *Catatan Kuliah Pengantar Pengolahan Citra*.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2015). Rethinking the Inception Architecture for Computer Vision. *Arxiv*, 3, 1–6.
- Walid, Sugiman, & Wiyanti, D. T. (2018). Analisis Produktivitas Kinerja Dosen dan Tenaga Kependidikan dalam Mewujudkan Tahun Reputasi Universitas Negeri Semarang (UNNES) Menggunakan Jaringan Saraf Tiruan, 1, 919–927.
- Williams, M. A., Craig, D., Passmore, P., & Silvestri, G. (2009). Retinal drusen: Harbingers of age, safe havens for trouble. *Age and Ageing*, 38(6), 648–654.
- Wong, W. L., Su, X., Li, X., Cheung, C. M. G., Klein, R., Cheng, C. Y., & Wong,

- T. Y. (2014). Global prevalence of age-related macular degeneration and disease burden projection for 2020 and 2040: A systematic review and meta-analysis. *The Lancet Global Health*, 2(2), e106–e116.
- Wu, L. (2019). Choroidal Neovascularization (CNV). *Ophthalmology*, 93(9), 1169–1176.
- Wuryandari, T., & Warsito, B. (2012). Pemilihan Arsitektur Optimal Model NN dengan Metode Kontribusi Increment. *Jurnal Matematika UNDIP*, 234–242.
- Yaseen, Z. M., Ghareb, M. I., Ebtehaj, I., Bonakdari, H., Siddique, R., Heddami, S., Deo, R. dkk. (2018). Rainfall Pattern Forecasting Using Novel Hybrid Intelligent Model Based ANFIS-FFA. *Water Resources Management*, 32(1), 105–122.
- Zeiler, M. D., & Fergus, R. (2014). Visualizing and Understanding Convolutional Networks. *European Conference on Computer Vision (ECCV)*, 8689(Chapter 53), 818–833.
- Zhang, J., & Wu, Y. (2018). Complex-valued unsupervised convolutional neural networks for sleep stage classification. *Computer Methods and Programs in Biomedicine*, 164, 181–191.