

**KLASIFIKASI TINGKAT KEGANASAN KANKER SERVIKS
MENGUNAKAN METODE *DEEP RESIDUAL NETWORK* (RESNET)**

SKRIPSI



**UIN SUNAN AMPEL
S U R A B A Y A**

Disusun Oleh
PUTRI WULANDARI
H72216063

**PROGRAM STUDI MATEMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI SUNAN AMPEL
SURABAYA**

2019

PERNYATAAN KEASLIAN

Saya yang bertanda tangan di bawah ini,

Nama : Putri Wulandari

NIM : H72216063

Program Studi : Matematika

Angkatan : 2016

Menyatakan bahwa saya tidak melakukan plagiat dalam penulisan skripsi saya yang berjudul ” Klasifikasi Tingkat Keganasan Kanker Serviks Menggunakan Metode *Deep Residual Network* (ResNet) ”. Apabila suatu saat nanti terbukti saya melakukan tindakan plagiat, maka saya bersedia menerima sanksi yang telah ditetapkan.

Demikian pernyataan keaslian ini saya buat dengan sebenar-benarnya.

Surabaya, 31 Desember 2019

Yang menyatakan,



Putri Wulandari
NIM. H72216063

LEMBAR PERSETUJUAN PEMBIMBING

Skripsi oleh

Nama : Putri Wulandari

NIM : H72216063

Judul Skripsi : Klasifikasi Tingkat Keganasan Kanker Serviks
Menggunakan Metode *Deep Residual Network* (ResNet)

telah diperiksa dan disetujui untuk diujikan.

Surabaya, Desember 2019

Pembimbing



Dian Candra Rini Novitasari, M.Kom
NIP. 19851124 201403 2 001

PENGESAHAN TIM PENGUJI SKRIPSI

Skripsi oleh

Nama : Putri Wulandari
NIM : H72216063
Judul Skripsi : Klasifikasi Tingkat Keganasan Kanker Serviks
Menggunakan Metode *Deep Residual Network* (ResNet)

Telah dipertahankan di depan Tim Penguji
pada tanggal 30 Desember 2019

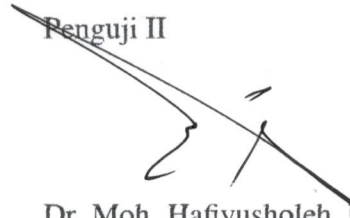
Mengesahkan,
Tim Penguji

Penguji I



Dian Candra Rini Novitasari, M.Kom
NIP. 19851124 201403 2 001

Penguji II



Dr. Moh. Hafiyusholeh, M.Si, M.PMat
NIP. 19800204 201403 1 001

Penguji III




Aris Fanani, M.Kom
NIP. 19870127 201403 1 002

Penguji IV



Wika Dianita Utami, M.Sc
NIP. 19920610 201801 2 003

Mengetahui,
Dekan Fakultas Sains dan Teknologi
UIN Sunan Ampel Surabaya



Dr. Hj. Eni Purwati, MAg
NIP. 19651221 199002 2 001



KEMENTERIAN AGAMA
UNIVERSITAS ISLAM NEGERI SUNAN AMPEL SURABAYA
PERPUSTAKAAN

Jl. Jend. A. Yani 117 Surabaya 60237 Telp. 031-8431972 Fax.031-8413300
E-Mail: perpus@uinsby.ac.id

LEMBAR PERNYATAAN PERSETUJUAN PUBLIKASI
KARYA ILMIAH UNTUK KEPENTINGAN AKADEMIS

Sebagai sivitas akademika UIN Sunan Ampel Surabaya, yang bertanda tangan di bawah ini, saya:

Nama : PUTRI WULANDARI
NIM : H72216063
Fakultas/Jurusan : SAINS DAN TEKNOLOGI / MATEMATIKA
E-mail address : 22putriw@gmail.com

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Perpustakaan UIN Sunan Ampel Surabaya, Hak Bebas Royalti Non-Eksklusif atas karya ilmiah :

Sekripsi Tesis Desertasi Lain-lain (.....)
yang berjudul :

KLASIFIKASI TINGKAT KEGANASAN KANKER SERVIKS MENGGUNAKAN

METODE DEEP RESIDUAL NETWORK (RESNET)


beserta perangkat yang diperlukan (bila ada). Dengan Hak Bebas Royalti Non-Eksklusif ini Perpustakaan UIN Sunan Ampel Surabaya berhak menyimpan, mengalih-media/format-kan, mengelolanya dalam bentuk pangkalan data (database), mendistribusikannya, dan menampilkan/mempublikasikannya di Internet atau media lain secara *fulltext* untuk kepentingan akademis tanpa perlu meminta ijin dari saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan atau penerbit yang bersangkutan.

Saya bersedia untuk menanggung secara pribadi, tanpa melibatkan pihak Perpustakaan UIN Sunan Ampel Surabaya, segala bentuk tuntutan hukum yang timbul atas pelanggaran Hak Cipta dalam karya ilmiah saya ini.

Demikian pernyataan ini yang saya buat dengan sebenarnya.

Surabaya, 31 Desember 2019

Penulis


(PUTRI WULANDARI)

2.3.3.	Pemeriksaan HPV	28
2.3.4.	Pemeriksaan Kolposkopi	28
2.3.5.	Pemeriksaan Biopsi Serviks	30
2.4.	Citra Digital	30
2.4.1.	Citra Biner	32
2.4.2.	Citra Grayscale	32
2.4.3.	Citra Warna (<i>True Color</i>)	33
2.5.	Augmentasi Data	33
2.6.	<i>Artificial Intelligence</i>	36
2.7.	<i>Machine Learning</i>	38
2.7.1.	<i>Supervised Learning</i>	39
2.7.2.	<i>Unsupervised Learning</i>	39
2.7.3.	<i>Reinforcement Learning</i>	40
2.8.	<i>Neural Network</i>	40
2.9.	<i>Deep Learning</i>	41
2.10.	<i>Convolutional Neural Network</i>	42
2.10.1.	<i>Convolution Layer</i>	44
2.10.2.	<i>Batch Normalization</i>	47
2.10.3.	<i>Activation Layer</i>	48
2.10.4.	<i>Pooling Layer</i>	51
2.10.5.	<i>Flatten atau Reshape</i>	52
2.10.6.	<i>Fully Connected Layer</i>	52
2.10.7.	<i>Softmax</i>	54
2.10.8.	<i>Cross Entropy</i>	54
2.10.9.	<i>Stochastic Gradient Descent with Momentum</i>	55
2.11.	Arsitektur CNN	56
2.12.	<i>Deep Residual Network (ResNet)</i>	60
2.13.	<i>Confussion Matrix</i>	62
	III METODE PENELITIAN	64
3.1.	Jenis Penelitian	64

3.2. Jenis Data	64
3.3. Teknik Analisis Data	65
3.4. Perancangan Uji Coba	68
IV HASIL DAN PEMBAHASAN	69
4.1. Pembelajaran Model	69
4.1.1. <i>Preprocessing</i>	70
4.1.2. Pelatihan Model ResNet	76
4.1.3. Pengujian Model ResNet	101
4.2. Evaluasi Model	102
4.3. Aplikasi Identifikasi Tingkat Keganasan Kanker Serviks	107
V PENUTUP	110
5.1. Simpulan	110
5.2. Saran	111
DAFTAR PUSTAKA	112

2.24	Ilustrasi	53
2.25	Contoh Jaringan Klasik dari LeNet-5	56
2.26	Contoh Jaringan Klasik dari AlexNet	57
2.27	Contoh Jaringan Klasik VGGNet	59
2.28	Contoh Jaringan ResNet	59
2.29	Blok Deep Residual Network	60
2.30	Perbandingan jaringan biasa dengan jaringan ResNet	61
2.31	Arsitektur ResNet	61
3.1	Diagram Alir Klasifikasi Tingkat Keganasan Kanker Serviks	65
4.1	Citra Kolposkopi: (a) Serviks Normal, (b) Kanker Serviks Stadium I, (c) Kanker Serviks Stadium II, (d) Kanker Serviks Stadium III, (d) Kanker Serviks Stadium IV	70
4.2	<i>Channel</i> Warna Citra Kolposkopi	70
4.3	Sampel Matriks Citra Kolposkopi Ukuran 16×16	72
4.4	Hasil Transformasi Rotasi	74
4.5	Hasil Transformasi Refleksi	75
4.6	Contoh Citra Hasil Transformasi Geometri	75
4.7	Perancangan Arsitektur ResNet-18	77
4.8	Perancangan Arsitektur ResNet-50	77
4.9	Perancangan Arsitektur ResNet-101	78
4.10	Ilustrasi Operasi Konvolusi Pada Sampel Citra	79
4.11	Ilustrasi Operasi Konvolusi Citra <i>Channel Red</i>	80
4.12	Ilustrasi Operasi Konvolusi Citra <i>Channel Green</i>	82
4.13	Ilustrasi Operasi Konvolusi Citra <i>Channel Blue</i>	84
4.14	<i>Feature Map</i> Hasil Konvolusi Pertama	86
4.15	Hasil <i>Feature Map</i> : (a) <i>Batch Normalization Layer</i> , (b) <i>ReLU Layer</i>	88
4.16	<i>Residual Block</i> pada Bagian Arsitektur ResNet	91
4.17	<i>Lapisan Klasifikasi</i>	93
4.18	Pelatihan Model ResNet-18	100
4.19	Pelatihan Model ResNet-50	101

sebab tidak semua HPV dapat menyebabkan kanker serviks. Penderita penyakit HPV dengan daya tahan tubuh lemah lebih berpotensi mengalami pertumbuhan kanker serviks apabila dibandingkan penderita HPV dengan daya tahan tubuh yang kuat (Deverakonda, 2016).

Kanker serviks memiliki julukan sebagai '*Silent Killer*' karena pada tahap awal kanker tidak terdapat indikasi atau gejala penyakit kanker yang terlihat (Devi, 2016). Gejala fisik yang menandai adanya kanker serviks di antaranya adalah terjadi keputihan dengan bau yang tidak sedap akibat adanya infeksi dan nekrosis pada jaringan dalam vagina (Darmawati, 2010). Selain itu, kanker serviks dapat pula ditandai dengan adanya perdarahan yang tidak biasa pada vagina, terjadi ketidakteraturan pada siklus haid, terjadi nyeri pada bagian panggul, punggung, dan kaki, serta mengalami sakit pada vagina saat sedang menstruasi atau melakukan koitus (Deverakonda, 2016).

Terdapat dua jenis kanker serviks yaitu *squamous carcinoma* dan *adenocarcinoma*. *Squamous carcinoma* merupakan penyebab sel-sel pada bagian permukaan luar *ectocervix* atau bagian luar dari leher rahim berubah menjadi sel kanker. Sedangkan *adenocarcinoma* menyebabkan sel-sel kelenjar yang menghasilkan lendir pada *ectocervix* berubah menjadi sel-sel kanker (Devi, 2016). Pertumbuhan kanker serviks membutuhkan beberapa tahun sejak dimulainya perubahan abnormal pada sel-sel dalam rahim. Lesi awal kanker serviks dimulai dengan adanya displasia serviks atau *cervical intraepithelial neoplasia* (CIN), di mana hal tersebut merupakan suatu kondisi terjadinya perubahan abnormal namun bukan kanker pada sel rahim. Dalam 10 sampai 20 tahun ke depan apabila tidak segera ditangani, kondisi tersebut dapat berubah menjadi kanker serviks (Garg, 2017).

yang dimiliki separah apapun penyakit tersebut, asalkan hamba-Nya terus berdoa kepada-Nya dan tetap berusaha. Bentuk usaha yang dilakukan oleh manusia adalah dengan melakukan perawatan medis yang sesuai dengan penyakit yang diderita, dimana perawatan yang tepat didasarkan pada diagnosa yang tepat. Pendeteksian dini suatu penyakit secara tepat dapat mencegah dan/atau menunda kematian akibat suatu penyakit.

Saat ini, diagnosis penyakit menggunakan *artificial intelligence* (AI) telah banyak digunakan ahli medis untuk membantu dalam mendiagnosis beragam jenis kanker, termasuk kanker serviks. Dalam suatu studi, AI yang digunakan para medis sebagai suatu sistem pendukung keputusan menunjukkan adanya peningkatan dalam pendeteksian kanker. Selain itu, penggunaan sistem AI mampu mengurangi jumlah waktu yang digunakan untuk menganalisis citra.

Berbagai metode pemrosesan citra telah dikembangkan untuk mendeteksi citra hasil pemeriksaan kolposkopi, diantaranya adalah penelitian yang dilakukan oleh Gordon, dkk. dengan menerapkan model *Gaussian Mixture* untuk melakukan segmentasi pada tiga jaringan epitel, yaitu *squamous*, *columnar*, dan *acetowhite* menggunakan informasi warna dan tekstur (Gordon, 2006). Ji, dkk. melakukan analisis tekstur untuk mengklasifikasikan pola vaskular dari citra kolposkopi (Ji, 2000). Selain itu, beberapa pendekatan klasifikasi berbasis *neural network* juga telah dikembangkan, misalnya metode klasifikasi sederhana untuk mengetahui kontur lesi kolposkopi menggunakan *artificial neural network* (ANN) (Claude, 2002) dan klasifikasi jaringan serviks berdasarkan data spektral menggunakan *multi-layered perceptrons* dan jaringan *Radial Basis Function* (Tumer, 1998). Berbagai contoh di atas merupakan satu dari sekian metode AI yang digunakan untuk menganalisis citra secara otomatis dalam mendeteksi kanker serviks (Li,

2005).

Dalam beberapa tahun terakhir, *machine learning* sebagai bagian dari AI secara persisten melakukan pengembangan dan perbaikan-perbaikan dalam algoritmanya, salah satunya adalah *deep learning*. *Deep learning* (DL) sendiri merupakan pengembangan dari algoritma ANN di mana proses ekstraksi fitur dan klasifikasi dapat dilakukan dalam satu arsitektur DL. Pada DL pembelajaran dapat diterapkan dalam beragam jenis permasalahan, diantaranya adalah pengenalan pola, suara, dan citra, klasifikasi teks, dan sebagainya (Ciregan, 2012). Adapun algoritma DL yang umum digunakan diantaranya adalah *deep neural networks*, *deep belief networks*, *recurrent neural networks*, dan *convolutional neural networks*.

Berdasarkan penelitian Xu, dkk., *convolutional neural networks* (CNN) merupakan salah satu metode DL yang mampu mendeteksi kanker dengan kinerja yang menjanjikan (Xu, 2015). Pada penelitian Jiang, dkk, juga menjelaskan bahwa teknologi yang menggunakan algoritma CNN telah mencapai keberhasilan dalam mengklasifikasi citra alami dan citra biomedis (Jiang, 2019). Brinker, dkk, dalam penelitiannya berhasil menunjukkan bahwa CNN dapat digunakan untuk mengklasifikasikan tingkatan penyakit kulit berdasarkan lesi yang mencurigakan pada citra *dermoscopic* (Brinker, 2019). Sasikala, dkk. melakukan pendekatan dengan memanfaatkan metode CNN untuk mengklasifikasikan tumor yang berada di organ paru-paru ke dalam kelas *benign* dan *malign*. Akurasi yang diperoleh dalam penelitian tersebut sebesar 96%, di mana hasil yang diperoleh dari penelitian tersebut lebih baik apabila dibandingkan dengan sistem jaringan saraf tradisional (Sasikala, 2018). Jiang, dkk. melakukan klasifikasi citra histopatologi kanker payudara menggunakan CNN dengan arsitektur SE-ResNet sebagai bentuk

pengembangan untuk mencapai kinerja yang baik dengan parameter yang lebih sedikit. Hasil penelitian yang dilakukan menunjukkan bahwa model yang dibangun oleh Jiang, dkk. mencapai akurasi antara 98,87% sampai 99,34% untuk klasifikasi dua kelas dan 90,66% sampai 93,81% untuk klasifikasi banyak kelas (Jiang, 2019). Dalam penelitian Vasudha, dkk., metode CNN juga telah diterapkan pada dataset citra kolposkopi untuk diklasifikasikan ke dalam kelas normal dan kanker. Pada penelitian tersebut arsitektur CNN yang digunakan merupakan arsitektur LeNet, di mana hasil akurasi yang diperoleh dari penelitian tersebut cukup baik dalam mengklasifikasikan kanker serviks, sehingga keputusan untuk jenis perawatan yang tepat untuk dapat diambil (Vasudha, 2018).

Berdasarkan penelitian-penelitian di atas, Algoritma CNN telah banyak digunakan oleh para peneliti dalam menganalisis suatu objek, sebab algoritma ini telah diklaim sebagai model terbaik dalam menyelesaikan permasalahan pengenalan objek (Ker, 2017)(Hakim, 2018). Beragam arsitektur CNN telah diusulkan oleh beberapa peneliti di masa lalu, di antaranya adalah LeNet, AlexNet, ZFNet, GoogleNet, VGGNet, dan ResNet (Munir, 2019). Arsitektur ResNet dapat mengklasifikasikan citra pada dataset ImageNet dengan tingkat akurasi yang tinggi, yaitu sebesar 80.62% untuk Top-1 (He, 2016) serta telah memenangkan beberapa kompetisi pada tahun 2015 dengan mengalahkan arsitektur AlexNet, GoogleNet dan VGGNet.

Berdasarkan uraian permasalahan yang telah dijelaskan di atas, maka penelitian yang dilakukan penulis adalah membangun suatu sistem klasifikasi tingkat keganasan kanker serviks pada citra kolposkopi menggunakan metode CNN. Karena terdapat beragam jenis arsitektur yang dapat digunakan pada metode CNN, maka pada penelitian ini model arsitektur yang digunakan merupakan

koitus, dan lain sebagainya (Darmawati, 2010). Pada fase lanjut terasa nyeri hebat yang menjalar sampai kaki. Beberapa dampak dari penyakit ini adalah hilangnya nafsu makan, terjadi penurunan berat badan, badan tampak lemah, nyeri pada bagian panggul, punggung, dan kaki, kaki bengkak, dan lain sebagainya (Deverakonda, 2016).

2.2.1. Stadium 0

Kanker serviks stadium 0 atau *cervical carcinoma in situ* merupakan awal dari tumbuhnya sel kanker pada serviks dengan ditemukannya sel-sel abnormal pada permukaan epitel serviks. Dalam beberapa tahun, sel-sel tersebut akan menyebar ke jaringan sekitar dan berkembang menjadi sel kanker. Pada stadium ini gejala fisik dari kanker serviks belum dapat dideteksi. Gejala baru akan muncul setelah sel kanker berkembang pada stadium selanjutnya (Anggriyani, 2015).

2.2.2. Stadium I

Kanker serviks stadium I merupakan tahap awal tumbuhnya sel kanker yang hanya ditemukan pada leher rahim (serviks). Stadium ini terdiri dari stadium IA dan IB, kemudian dikelompokkan kembali menjadi stadium IA₁, stadium IA₂, stadium IB₁, dan stadium IB₂ berdasarkan jumlah kanker yang ditemukan. Pada stadium IA₁, kanker tumbuh kurang dari 3 mm. Sedangkan pada stadium IA₂, kanker telah tumbuh antara 3-5 mm ke dalam jaringan serviks dengan lebar kurang dari 7 mm. Pada stadium IB₁, kanker berkembang menjadi lebih besar, tetapi ukurannya tidak sampai lebih dari 4 cm. Sedangkan pada stadium IB₂, secara horizontal ukuran kanker mencapai lebih dari 4 cm dalam ukuran horizontal (Masrurroh, 2016).

2.3. Pemeriksaan Kanker Serviks

Pada setiap jenis kanker pendeteksian dan perawatan yang dilakukan berbeda-beda tergantung jenis kanker yang diderita. Pemeriksaan kanker serviks dapat dilakukan dengan beberapa cara. Berikut beberapa pemeriksaan yang umum dilakukan untuk mendeteksi adanya kanker pada organ serviks.

2.3.1. Pemeriksaan IVA (Inspeksi Visual Asam Laktat)

Pemeriksaan IVA atau sering juga disebut sebagai inspeksi visual asam laktat merupakan salah satu pemeriksaan yang umum dilakukan untuk mendeteksi adanya kanker serviks sejak dini (Kemenkes RI, 2019), sebab pemeriksaan ini mampu mendeteksi lesi pada tingkat pra kanker dengan sensitivitas sampai 96% dan spesifisitas mencapai 98% (Handayani, 2012). Pemeriksaan IVA ini dilakukan dengan cara mengoleskan larutan asam asetat 3 – 5% pada serviks. Kemudian dilakukan pengamatan langsung dari perubahan warna pada serviks. Apabila serviks berwarna merah berarti hasil pemeriksaan tersebut menunjukkan bahwa serviks normal. Sedangkan, apabila terdapat perubahan seperti adanya bercak putih menandakan bahwa terdapat lesi CIN (Anggriyani, 2015).

2.3.2. Pemeriksaan Pap Smear

Pap smear merupakan suatu cara mendeteksi kanker serviks yang paling umum dilakukan. Pemeriksaan ini termasuk ke dalam jenis pemeriksaan sitologi, dimana pemeriksaan ini dilakukan dengan cara mengambil spesimen pada serviks. Hasil yang dapat diperoleh dari pemeriksaan ini meliputi normal smear, proses peradangan, *low grade intraepithelial lesion (LSIL)*, *high grade intraepithelial lesion (HSIL)*, *carcinoma in situ*, dan *carcinoma invasive* (Mastutik, 2015).

2.6. *Artificial Intelligence*

Artificial Intelligence (AI) atau kecerdasan buatan lahir pertama kali pada tahun 1950-an saat para pencetus teknologi komputer memikirkan bagaimana komputer dapat berpikir (Chollet, 2018). AI didefinisikan sebagai kecerdasan dari entitas ilmiah yang umumnya dianggap seperti komputer. AI diciptakan dengan tujuan agar dapat melakukan pekerjaan manusia secara otomatis. AI telah digunakan pada bermacam-macam bidang, seperti sistem ahli, robotika, permainan, logika fuzzy, *artificial neural network*, dan sebagainya (Pujoseno, 2018).

Pada tahun 1950-an sampai 1980-an, para ahli meyakini bahwa kecerdasan buatan dapat dicapai dengan membangun suatu program yang berisikan seperangkat aturan eksplisit dalam jumlah besar untuk memanipulasi pengetahuan atau paradigma tersebut umumnya disebut sebagai AI simbolik. Meskipun AI simbolik terbukti dapat menyelesaikan beragam masalah logis yang terdefinisi dengan baik seperti bermain catur, namun AI simbolik sulit menemukan aturan eksplisit untuk permasalahan kompleks dan fuzzy, seperti klasifikasi citra, pengenalan suara, dan terjemahan bahasa. Oleh karenanya kemudian lahir *machine learning* (Chollet, 2018).

Berdasarkan Gambar 2.15, secara umum AI mencakup *machine learning* dan *deep learning*, tetapi AI juga dapat mencakup pendekatan yang tidak memerlukan pembelajaran.

2.7. Machine Learning

Machine Learning (ML) diperkenalkan pertama kali oleh Arthur Samuel pada tahun 1959. Menurut Mohri, ML didefinisikan sebagai suatu metode komputasi yang didasarkan pada informasi yang telah dilatih sebelumnya untuk meningkatkan performa *machine* dalam menentukan prediksi secara akurat (Pujoseno, 2018). ML memungkinkan seseorang untuk menyelesaikan permasalahan yang sulit untuk diselesaikan melalui program yang telah ditulis dan dirancang oleh manusia. Berdasarkan sudut pandang filosofis dan ilmiah, ML menarik karena mampu mengembangkan pemahaman mengenai prinsip-prinsip yang mendasari kecerdasannya (Goodfellow, 2016).

Terdapat beragam jenis permasalahan yang dapat diselesaikan dengan menggunakan ML. Berikut merupakan beberapa permasalahan yang umumnya diselesaikan oleh ML.

1. Klasifikasi
2. Regresi
3. Transkripsi
4. Mesin Translasi
5. Deteksi Anomali
6. Estimasi Fungsi Massa Probabilitas; dan lain sebagainya.

Neural Network (NN) merupakan salah satu algoritma ML yang mengadaptasi cara kerja jaringan saraf manusia. Otak manusia terdiri dari milyaran neuron yang dihubungkan oleh *synapses*, dimana dendrit bertugas sebagai penerima informasi yang masuk untuk diteruskan dan diproses oleh *nukleus* (inti sel). Sedangkan akson bertugas untuk mengirimkan impuls atau keluaran hasil pemrosesan informasi dari badan sel ke jaringan lain (Nurhikmat, 2018).

2.9. Deep Learning

Deep Learning (DL) merupakan sub-bidang ML sebagai hasil dari pengembangan NN (Alom , 2018). Pengenalan pola atau pengolahan informasi dari data non linier pada DL dapat melakukan ekstraksi fitur dan klasifikasi sekaligus pada kumpulan data dalam jumlah yang besar (Hakim, 2018)(Nurhikmat, 2018). Umumnya pembelajaran ML hanya menggunakan satu atau dua lapisan untuk merepresentasikan data, sehingga pembelajaran tersebut sering disebut sebagai pembelajaran dangkal. Berbeda dengan pembelajaran ML biasa, pembelajaran DL ini lebih dikenal sebagai algoritma pembelajaran dengan jumlah lapisan berurutan yang banyak dengan tujuan agar data dapat direpresentasikan dengan baik (Chollet, 2018). Sejak diperkenalkan pada awal tahun 2006, DL telah digunakan pada bidang yang luas dan beragam, di antaranya adalah pengenalan suara, pengenalan citra, pengenalan bahasa, penemuan obat, bioinformatika, dan lain sebagainya secara otomatis (Alom , 2018).

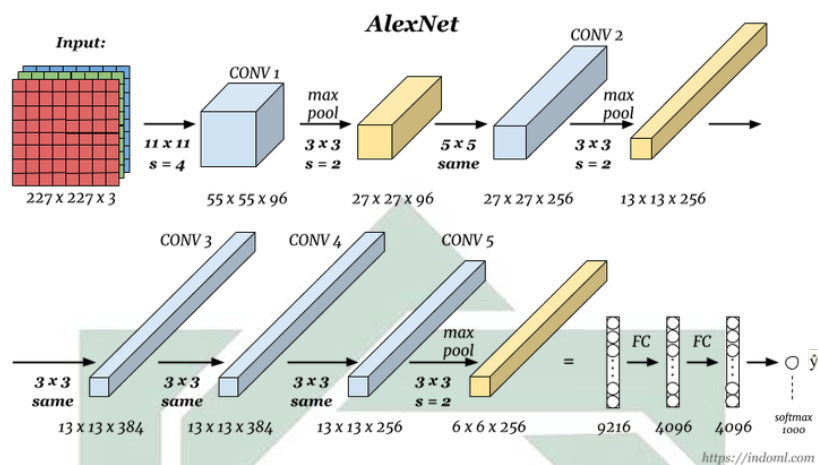
Seperti ML, algoritma ini memiliki jenis pembelajaran terawasi dan tidak terawasi. Model pembelajaran terawasi pada DL misalnya *Convolutional Neural Network* (CNN), *Recurrent Neural Network* (RNN), *Long Short Term Memory* (LSTM), *Gated Recurrent Units* (GRU) dan lain sebagainya. Sedangkan model

c. Fungsi Tanh

$$\begin{aligned}
g(x) &= \frac{2}{1 + e^{-2x}} - 1 & (2.25) \\
\frac{\partial g(x)}{\partial x} &= \frac{-2(-2e^{-2x})}{(1 + e^{-2x})^2} = \frac{4e^{-2x}}{(1 + e^{-2x})^2} \\
&= \frac{4}{1 + e^{-2x}} \frac{e^{-2x}}{1 + e^{-2x}} \\
&= \frac{4}{1 + e^{-2x}} \frac{e^{-2x} + 1 - 1}{1 + e^{-2x}} \\
&= \frac{4}{1 + e^{-2x}} \left(\frac{1 + e^{-2x}}{1 + e^{-2x}} - \frac{1}{1 + e^{-2x}} \right) \\
&= \frac{4}{1 + e^{-2x}} \left(1 - \frac{1}{1 + e^{-2x}} \right) \\
&= \frac{4}{1 + e^{-2x}} - \frac{4}{(1 + e^{-2x})^2} \\
&= 4 \left[\frac{1}{1 + e^{-2x}} \right] - 4 \left[\frac{1}{(1 + e^{-2x})^2} \right] \\
&= 4 \left[\frac{1}{2} \left[\left(\frac{2}{1 + e^{-2x}} - 1 \right) + 1 \right] \right] \\
&\quad - 4 \left[\frac{1}{4} \left[\left(\frac{2}{1 + e^{-2x}} - 1 \right)^2 + 2 \left(\frac{2}{1 + e^{-2x}} - 1 \right) + 1 \right] \right] \\
&= 2 \left[\left(\frac{2}{1 + e^{-2x}} - 1 \right) + 1 \right] \\
&\quad - \left[\left(\frac{2}{1 + e^{-2x}} - 1 \right)^2 + 2 \left(\frac{2}{1 + e^{-2x}} - 1 \right) + 1 \right] \\
&= 2 \left(\frac{2}{1 + e^{-2x}} - 1 \right) + 2 - \left(\frac{2}{1 + e^{-2x}} - 1 \right)^2 - 2 \left(\frac{2}{1 + e^{-2x}} - 1 \right) - 1 \\
&= 1 - \left(\frac{2}{1 + e^{-2x}} - 1 \right)^2 & (2.26)
\end{aligned}$$

Fungsi $g(x)$ merupakan fungsi non-linear dengan x merupakan nilai-nilai dalam matriks *feature map* dengan nilai keluaran berada dalam rentang $(-1, 1)$

b. AlexNet



Gambar 2.26 Contoh Jaringan Klasik dari AlexNet

(Sumber : *indoml.com*)

AlexNet merupakan arsitektur pemenang tantangan pada tahun 2012, dengan mengurangi kesalahan Top-5 dari 26% menjadi 15.3%. Jaringan ini menyerupai LeNet tetapi memiliki kemampuan pembelajaran lebih dalam. Ia melakukan peningkatan jumlah filter setiap lapisan dan menyusun lebih banyak lapisan *convolutional* untuk ditumpuk. Arsitektur ini terdiri dari 11×11 , 5×5 , dan 3×3 kernel *convolutional*, *max pooling*, *dropout*, augmentasi data, dan aktivasi ReLU. Aktivasi ReLU dilampirkan setiap setelah *convolutional layer* dan *fully connected layer*. Diperlukan waktu selama dua hari untuk menguji jaringan ini pada GPU580 Nvidia Geforce, oleh sebab itu jaringan ini dibagi menjadi dua saluran pipa. Desainer AlexNet terdiri dari Alex Krizhevsky, Geoffrey Hinton, dan Ilya Sutskever.

c. ZFNet

ZFNet merupakan pemenang *ImageNet Large Scale Visual Recognition Competition* (ILSVRC) pada tahun 2013. Para peneliti mampu mengurangi

2.13. *Confussion Matrix*

Evaluasi kinerja pada suatu sistem klasifikasi merupakan sesuatu yang penting untuk mengetahui seberapa baik sistem yang dibangun dalam mengklasifikasikan data (Prasetyo, 2012). Berdasarkan jumlah kelas pada keluaran hasil sistem klasifikasi, jenis klasifikasi dikelompokkan menjadi empat jenis yaitu klasifikasi biner, *multi-case*, *multi-label*, dan *hierarchical* (Sokolova, 2009). Pada pengukuran kinerja sistem klasifikasi umumnya digunakan *confussion matrix* untuk membandingkan hasil klasifikasi oleh sistem dengan hasil klasifikasi sesungguhnya. Pada *confussion matrix*, dikenal empat istilah berupa *True Positive* (TP), *True Negative* (TN), *False Positive* (FP) dan *False Negative* (FN) untuk mempresentasikan hasil perbandingan klasifikasi sistem dengan klasifikasi sesungguhnya.

True positive (TP) adalah klasifikasi yang benar dari kelas positif, misalnya jika citra mengandung sel kanker dan model segmen kanker bagian berhasil dan hasilnya mengklasifikasikan keberadaan kanker. *True negative* (TN) adalah klasifikasi yang benar dari kelas negatif, misalnya tidak ada kanker hadir dalam citra dan model setelah klasifikasi menyatakan bahwa kanker tidak ada. *False positive* (FP) adalah prediksi salah yang positif, misalnya citra memang memiliki sel kanker tetapi model mengklasifikasikan bahwa citra tidak mengandung kanker di dalamnya. *False negative* (FN) adalah prediksi salah yang negatif, misalnya tidak ada kanker dalam citra tetapi model mengatakan citra adalah kanker (Munir, 2019).

Nilai *accuracy*, *specificity*, dan *sensitivity* digunakan untuk menguji tingkat akurasi pengklasifikasian data pengujian berdasarkan pelatihan yang telah dilakukan. Nilai *accuracy* merupakan nilai yang mengukur seberapa besar tingkat

dengan ukuran citra yang berbeda-beda sehingga langkah pertama yang perlu diterapkan adalah proses *cropping*. Pengolahan tersebut dilakukan untuk memperoleh bagian tertentu pada citra dengan ukuran yang sama. Pada penelitian ini, *cropping* dilakukan secara manual dengan ukuran 224×224 .

Kemudian, augmentasi data diterapkan pada sistem untuk memperbanyak jumlah dataset. Hal tersebut dilakukan karena semakin banyak data yang dilatih pada *deep learning*, semakin baik pula sistem dalam mengenali citra. Pada proses ini metode augmentasi data yang digunakan adalah transformasi geometrik yang terdiri dari rotasi, refleksi dan dilatasi. Penerapan transformasi rotasi pada citra kolposkopi menggunakan persamaan (2.3). Selanjutnya, untuk penerapan transformasi refleksi pada citra masukkan digunakan persamaan (2.4), persamaan (2.5), dan persamaan (2.6). Sedangkan, untuk penerapan transformasi dilatasi pada citra digunakan persamaan (2.7).

Setelah diterapkan augmentasi pada data, dilakukan proses pembagian data untuk tahapan pelatihan dan pengujian model. Pada penelitian ini, pembagian data yang digunakan untuk pelatihan dan pengujian model adalah 80:20. Hal tersebut bermakna bahwa 80% data dari keseluruhan data setelah diterapkan augmentasi data akan digunakan untuk pelatihan model, kemudian 20% sisanya akan digunakan untuk pengujian dari model yang telah dibangun.

2. Pelatihan Model

Pada tahapan pelatihan model, dilakukan pembelajaran model yang terdiri dari proses pembelajaran fitur dan klasifikasi. Dalam penelitian ini, tahapan untuk ekstraksi fitur dan klasifikasi dilakukan dalam satu arsitektur.

Arsitektur CNN yang digunakan dalam penelitian ini adalah *Deep Residual Network* (ResNet). Arsitektur ResNet terdiri dari beberapa *convolution layer*, *batch normalization*, *activation layer* dan *pooling layer* untuk tahapan pembelajaran fitur. Sedangkan pada tahapan klasifikasi terdiri atas *fully connected layer* dan fungsi aktivasi *softmax*. Hasil klasifikasi diperoleh menggunakan persamaan (2.29), dimana nilai masukkan untuk persamaan tersebut diperoleh dari persamaan (2.28).

Dalam tahapan klasifikasi dilakukan perbaikan-perbaikan untuk parameter bobot dan bias untuk mencapai model yang optimal. Pembaruan parameter-parameter tersebut menggunakan metode *stochastic gradient descent with momentum* yang dinyatakan dalam persamaan (2.33). Untuk menyatakan seberapa baik model yang diberikan oleh jaringan yang dilatih, dilakukan perhitungan *loss function* menggunakan persamaan *cross entropy* yang dinyatakan dalam persamaan (2.31).

3. Pengujian Model

Model optimal yang diperoleh dari tahap pelatihan digunakan untuk mengklasifikasikan data pengujian. Proses pembelajaran fitur yang diterapkan pada saat pengujian sama dengan pelatihan model. Pada *classification layer*, data pengujian dijumlahkan dengan parameter-parameter yang telah optimal. Hasil dari klasifikasi dibandingkan dengan data aktual menggunakan *confusion matrix* untuk menghitung tingkat akurasi, sensitifitas, dan spesifisitas model dalam mengidentifikasi tingkat keganasan kanker serviks menggunakan persamaan (2.35), persamaan (2.36), dan persamaan (2.37).

4. Pembuatan Aplikasi

Berdasarkan perbandingan tingkat akurasi, sensitifitas, dan spesifisitas dari model percobaan yang dilatih untuk mengidentifikasi tingkat keganasan kanker serviks, model terbaik dari percobaan akan digunakan untuk membangun suatu sistem klasifikasi tingkat keganasan kanker serviks berdasarkan citra kolposkopi. Pada sistem tersebut, data citra kolposkopi akan dimuat ke dalam aplikasi untuk selanjutnya sistem akan mengidentifikasi tingkat keganasan kanker serviks ke dalam lima kelas, yaitu normal, stadium I, stadium II, stadium III, dan stadium IV.

3.4. Perancangan Uji Coba

Dalam arsitektur ResNet, terdapat beberapa jenis arsitektur yang dibedakan berdasarkan banyak jumlah *convolution layer* yang diterapkan pada tahap pembelajaran fitur. Pada penelitian ini, model arsitektur ResNet yang diterapkan untuk percobaan adalah ResNet-18, ResNet-50, dan ResNet-101. Dalam penyusunan arsitektur dari ketiga model tersebut, terdapat aturan dalam perangkaian *convolution layer*, *pooling layer*, dan *residual block*. Uraian mengenai penyusunan *layer* arsitektur ResNet dapat dilihat pada Gambar 2.27.

$$R = \begin{bmatrix} 222 & 220 & 215 & 212 & 211 & 214 & \cdots & 60 & 90 & 255 \\ 216 & 213 & 208 & 205 & 206 & 207 & \cdots & 63 & 91 & 255 \\ 218 & 214 & 209 & 207 & 212 & 216 & \cdots & 65 & 92 & 255 \\ 212 & 208 & 206 & 209 & 216 & 221 & \cdots & 62 & 91 & 255 \\ 204 & 203 & 203 & 206 & 211 & 213 & \cdots & 61 & 93 & 255 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots \\ 219 & 219 & 216 & 210 & 203 & 204 & \cdots & 93 & 112 & 252 \\ 221 & 219 & 215 & 208 & 203 & 202 & \cdots & 101 & 117 & 254 \end{bmatrix}$$

$$G = \begin{bmatrix} 114 & 112 & 109 & 106 & 107 & 110 & \cdots & 40 & 77 & 251 \\ 110 & 107 & 102 & 101 & 102 & 106 & \cdots & 43 & 78 & 251 \\ 114 & 110 & 105 & 106 & 111 & 116 & \cdots & 45 & 79 & 249 \\ 112 & 108 & 106 & 109 & 116 & 124 & \cdots & 45 & 79 & 247 \\ 109 & 108 & 106 & 109 & 114 & 118 & \cdots & 44 & 80 & 248 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots \\ 143 & 143 & 216 & 137 & 133 & 135 & \cdots & 67 & 101 & 247 \\ 145 & 143 & 215 & 135 & 133 & 136 & \cdots & 76 & 107 & 251 \end{bmatrix}$$

$$B = \begin{bmatrix} 150 & 148 & 145 & 142 & 142 & 145 & \cdots & 51 & 86 & 255 \\ 146 & 143 & 138 & 136 & 137 & 140 & \cdots & 54 & 87 & 255 \\ 149 & 145 & 140 & 140 & 145 & 150 & \cdots & 56 & 88 & 255 \\ 146 & 142 & 140 & 143 & 150 & 157 & \cdots & 55 & 88 & 253 \\ 141 & 140 & 139 & 142 & 147 & 150 & \cdots & 54 & 89 & 253 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots \\ 171 & 171 & 171 & 166 & 161 & 163 & \cdots & 70 & 99 & 243 \\ 173 & 171 & 170 & 164 & 161 & 163 & \cdots & 79 & 105 & 246 \end{bmatrix}$$

penelitian ini, pembagian data pelatihan dan pengujian dilakukan 80% data pelatihan dan 20% data pengujian. Sehingga, dari 2000 data terdapat 1600 data pelatihan yang terdiri 320 data untuk masing-masing kelas serviks normal, kanker serviks stadium I, stadium II, stadium III, dan stadium IV. Untuk tahap pengujian model terdapat 400 data pengujian dengan pada masing-masing kelas terdapat 80 data pengujian.

4.1.2. Pelatihan Model ResNet

Sebagaimana pembelajaran dalam *machine learning*, setelah melalui tahap *preprocessing*, umumnya dilanjutkan pada tahap ekstraksi fitur dan klasifikasi. Pada pembelajaran *deep learning* juga dilakukan hal yang sama namun berbeda. Pada *deep learning*, pembelajaran fitur dan klasifikasi dilakukan dalam satu proses yang sama. Pembentukan setiap *layer* arsitektur pada ResNet memiliki ketentuan sendiri. Pada pembelajaran fitur umumnya dilakukan dengan menerapkan *convolution layer*. Selain *convolution layer*, terdapat *batch normalization*, *activation layer* dan *pooling layer* dalam arsitektur ResNet. *Batch normalization* diterapkan setelah *convolution layer*, kemudian *activation layer* menggunakan fungsi aktivasi ReLu. Dalam masing-masing arsitektur ResNet tersebut, terdapat blok-blok residu yang membagi *convolution layer* ke dalam lima *layer*. *Pooling layer* hanya diterapkan pada awal pembelajaran fitur atau setelah konvolusi pertama dan tahap terakhir pembelajaran fitur atau setelah konvolusi terakhir sebelum dimasukkan ke dalam lapisan klasifikasi. Uraian mengenai penyusunan *layer* arsitektur ResNet dapat dilihat pada Gambar 2.27. Pada penelitian ini, jenis arsitektur yang digunakan adalah ResNet-18, ResNet-50, dan ResNet-101.

$$\begin{aligned}
s_1 &= \frac{e^{z_1}}{\sum_{d=1}^C e^{z_d}} \\
&= \frac{e^{-0.2554}}{e^{-0.2554} + e^{3.7458} + e^{-0.0570} + e^{-1.9242} + e^{-2.6564}} \\
&= \frac{0.7745905}{0.77459049 + 42.340858 + 0.94463748 + 0.14599137 + 0.070203826} \\
&= \frac{0.7745905}{44.2762833} = 0.017494475 \\
s_2 &= \frac{e^{z_2}}{\sum_{d=1}^C e^{z_d}} \\
&= \frac{e^{3.7458}}{e^{-0.2554} + e^{3.7458} + e^{-0.0570} + e^{-1.9242} + e^{-2.6564}} \\
&= \frac{42.340858}{0.77459049 + 42.340858 + 0.94463748 + 0.14599137 + 0.070203826} \\
&= \frac{42.340858}{44.2762833} = 0.95628756 \\
s_3 &= \frac{e^{z_3}}{\sum_{d=1}^C e^{z_d}} \\
&= \frac{e^{-0.0570}}{e^{-0.2554} + e^{3.7458} + e^{-0.0570} + e^{-1.9242} + e^{-2.6564}} \\
&= \frac{0.94463748}{0.77459049 + 42.340858 + 0.94463748 + 0.14599137 + 0.070203826} \\
&= \frac{0.94463748}{44.2762833} = 0.021335064 \\
s_4 &= \frac{e^{z_4}}{\sum_{d=1}^C e^{z_d}} \\
&= \frac{e^{-1.9242}}{e^{-0.2554} + e^{3.7458} + e^{-0.0570} + e^{-1.9242} + e^{-2.6564}} \\
&= \frac{0.14599137}{0.77459049 + 42.340858 + 0.94463748 + 0.14599137 + 0.070203826} \\
&= \frac{0.14599137}{44.2762833} = 0.0032972810 \\
s_5 &= \frac{e^{z_5}}{\sum_{d=1}^C e^{z_d}} \\
&= \frac{e^{-2.6564}}{e^{-0.2554} + e^{3.7458} + e^{-0.0570} + e^{-1.9242} + e^{-2.6564}} \\
&= \frac{0.070203826}{0.77459049 + 42.340858 + 0.94463748 + 0.14599137 + 0.070203826} \\
&= \frac{0.070203826}{44.2762833} = 0.0015855848
\end{aligned}$$

Dari persamaan diatas, akan digunakan untuk memperoleh nilai $\frac{\partial D}{\partial w_{ji}}$ dan $\frac{\partial D}{\partial b_j}$. Sehingga, untuk $\frac{\partial D}{\partial w_{ji}}$ diperoleh persamaan (4.3) dan untuk $\frac{\partial D}{\partial b_j}$ diperoleh persamaan (4.4).

$$\frac{\partial D}{\partial w_{ji}} = \frac{\partial D}{\partial z_j} \frac{\partial z_j}{\partial w_{ji}} = (s_j - p_j) \frac{\partial(\sum_{i=1}^c w_{ji}x_i + b_j)}{\partial w_{ji}} = (s_j - p_j)x_i \quad (4.3)$$

$$\frac{\partial D}{\partial b_j} = \frac{\partial D}{\partial z_j} \frac{\partial z_j}{\partial b_j} = (s_j - p_j) \frac{\partial(\sum_{i=1}^c w_{ji}x_i + b_j)}{\partial b_j} = (s_j - p_j) \quad (4.4)$$

Selanjutnya persamaan diatas digunakan untuk memperbarui nilai bobot dan bias. Pada penelitian ini, nilai learning rate η diinisialisasikan adalah 0.001. Untuk nilai α , secara umum digunakan $\alpha = 0.9$.

$$\begin{aligned} w_{jk}(t+1) &= w_{jk}(t) - \eta \frac{\partial D}{\partial w_{ji}} + \alpha \Delta w_{jk}(t-1) \\ &= w_{jk}(t) - 0.001(s_j - p_j)(t)x_i + 0.9\Delta w_{jk}(t-1) \\ b_j(t+1) &= b_j(t) - \eta \frac{\partial D}{\partial b_j} + \alpha \Delta b_j(t-1) \\ &= b_j(t) - 0.001(s_j - p_j)(t) + 0.9\Delta b_{jk}(t-1) \end{aligned}$$

Berikut merupakan contoh perhitungan untuk pembaruan bobot. Pada pembaruan bobot pertama, $\Delta w_{jk}(t-1)$ dan $\Delta b_j(t-1)$ belum dapat diperoleh, karena $\Delta w_{jk}(t-1)$ dan $\Delta b_j(t-1)$ merupakan nilai dari perubahan bobot dan bias terakhir kali. Sehingga pada contoh saat ini nilai $\Delta w_{jk}(t-1) = 0$ dan $\Delta b_j(t-1) = 0$.

$$w_{jk}(t+1) = w_{jk}(t) - 0.001(s_j - p_j)(t)x_i + 0.9\Delta w_{jk}(t-1)$$

$$w_{jk}(2) = w_{jk}(1) - 0.001(s_j - p_j)(1)x_i$$

$$= \begin{pmatrix} 0.0175 & -0.0020 & \dots & 0.0048 \\ -0.0066 & 0.0170 & \dots & -0.0200 \\ -0.0434 & 0.0067 & \dots & -0.0088 \\ 0.0253 & -0.0050 & \dots & 0.0135 \\ -0.0135 & 0.0056 & \dots & -0.0083 \end{pmatrix} -$$

$$0.001 \begin{pmatrix} 0.017494475 \\ -0.04371244 \\ 0.021335064 \\ 0.003297281 \\ 0.001585585 \end{pmatrix} \begin{pmatrix} 0.5854 & 0.5475 & 0.2458 & \dots & 1.6582 \end{pmatrix}$$

$$= \begin{pmatrix} 0.0175 & \dots & 0.0048 \\ -0.0066 & \dots & -0.0200 \\ -0.0434 & \dots & -0.0088 \\ 0.0253 & \dots & 0.0135 \\ -0.0135 & \dots & -0.0083 \end{pmatrix} - 0.001 \begin{pmatrix} 0.010240742 & \dots & 0.029009465 \\ -0.025587954 & \dots & -0.072484285 \\ 0.012488907 & \dots & 0.035377957 \\ 0.001930130 & \dots & 0.005467575 \\ 0.000928154 & \dots & 0.002629228 \end{pmatrix}$$

$$= \begin{pmatrix} 0.017453963 & -0.002047977 & \dots & 0.00476601 \\ -0.006587979 & 0.017068282 & \dots & -0.019970274 \\ -0.043400295 & 0.006639580 & \dots & -0.00882121 \\ 0.025302297 & -0.005001522 & \dots & 0.013534193 \\ -0.013455005 & 0.005572922 & \dots & -0.008263436 \end{pmatrix}$$

Tabel 4.1 Sampel Hasil Pengujian Model

Data ke-	Aktual	Prediksi		
		ResNet-18	ResNet-50	ResNet-101
1	Normal	Normal	Normal	Normal
2	Normal	Stadium 2	Normal	Normal
⋮	⋮	⋮	⋮	⋮
81	Stadium 1	Stadium 1	Stadium 1	Stadium 1
82	Stadium 1	Stadium 2	Stadium 1	Stadium 1
83	Stadium 1	Normal	Stadium 1	Stadium 1
⋮	⋮	⋮	⋮	⋮
224	Stadium 2	Stadium 3	Stadium 4	Normal
225	Stadium 2	Stadium 3	Stadium 4	Stadium 2
226	Stadium 2	Stadium 4	Stadium 4	Stadium 4
⋮	⋮	⋮	⋮	⋮
393	Stadium 4	Stadium 4	Stadium 4	Stadium 4
394	Stadium 4	Stadium 4	Stadium 4	Stadium 4
395	Stadium 4	Stadium 4	Stadium 4	Stadium 4
396	Stadium 4	Stadium 4	Stadium 4	Stadium 4
397	Stadium 4	Stadium 4	Stadium 4	Stadium 4
398	Stadium 4	Stadium 4	Stadium 4	Stadium 4
399	Stadium 4	Stadium 4	Stadium 4	Stadium 4
400	Stadium 4	Stadium 4	Stadium 4	Stadium 4

4.2. Evaluasi Model

Pada penelitian ini, terdapat tiga jenis percobaan yang dilakukan yaitu pembelajaran model arsitektur ResNet-18, ResNet-50, dan ResNet-101. Pembelajaran model tersebut dilakukan melalui dua tahapan yaitu pelatihan model dan pengujian model. Dari 2000 data hasil augmentasi, 80% dari keseluruhan data digunakan untuk pelatihan model dan sisanya digunakan untuk pengujian model. Hasil terbaik dari pembelajaran model ini akan digunakan untuk membangun sistem klasifikasi tingkat keganasan kanker serviks. Hasil keluaran pada klasifikasi ini ada lima kelas, yaitu normal, stadium I, stadium II, stadium III, dan stadium IV. Dari masing-masing model yang dilatih memiliki tingkat akurasi, sensitivitas, dan spesifitas sendiri. Dimana tingkat akurasi terbaik dianggap sebagai model yang

Tabel 4.5 Hasil Evaluasi Model ResNet-50

Tingkat Keganasan	Sensitifitas	Spesifisitas
Normal	98.8%	98.8%
Stadium I	96.3%	98.7%
Stadium II	92.5%	97.4%
Stadium III	100%	98.8%
Stadium IV	98.8%	92.9%

benar terklasifikasi sesuai dengan tingkat keganasannya. Pada pengujian data kanker serviks stadium II, terdapat 1 data kanker serviks stadium II terklasifikasi ke dalam stadium III dan 3 data kanker serviks stadium II terklasifikasi ke dalam stadium IV. Pada stadium III, terdapat 2 data terklasifikasi ke dalam kanker serviks stadium IV. Pada pengujian data kanker serviks stadium IV, keseluruhan data pengujian benar terklasifikasi ke dalam stadium IV. Dari hasil-hasil tersebut, hasil perhitungan tingkat sensitifitas dan spesifisitas disajikan dalam Tabel 4.6.

Tabel 4.6 Hasil Evaluasi Model ResNet-101

Tingkat Keganasan	Sensitifitas	Spesifisitas
Normal	98.8%	97.5%
Stadium I	97.5%	98.7%
Stadium II	93.8%	98.7%
Stadium III	97.5%	98.7%
Stadium IV	100%	94.1%

Berdasarkan hasil percobaan yang telah dipaparkan di atas, secara keseluruhan setiap model pembelajaran ResNet yang dilatih menghasilkan model yang baik dalam mengklasifikasikan tingkat keganasan kanker serviks. Dari ketiga percobaan yang dilakukan diperoleh hasil terbaik adalah dengan menggunakan arsitektur dengan *layer* konvolusi terbanyak, yaitu ResNet 101. Model tersebut memberikan tingkat akurasi sebesar 97.5% dalam mengklasifikasikan tingkat keganasan kanker serviks dengan sensitifitas sebesar 98.8%, 97.5%, 93.8%, 97.5%

kanker serviks pada citra kolposkopi dalam waktu ± 80 detik, dengan tingkat sensitifitas dalam mengenali tingkat keganasan kanker serviks sebesar 98.8%, 97.5%, 93.8%, 97.5% dan 100% untuk masing-masing kelas normal, stadium I, stadium II, stadium III, dan stadium IV. Untuk tingkat spesifisitas dari model tersebut diperoleh hasil sebesar 97.5%, 98.7%, 98.7%, 98.7%, dan 94.1% untuk masing-masing kelas normal, stadium I, stadium II, stadium III, dan stadium IV

5.2. Saran

Pada penelitian mengenai klasifikasi tingkat keganasan kanker serviks pada citra hasil pemeriksaan kolposkopi menggunakan metode ResNet ini masih memiliki beberapa kekurangan, sehingga perlu adanya perbaikan kembali di masa mendatang. Beberapa hal yang disarankan oleh peneliti untuk pengembangan ke depannya, diantaranya adalah :

1. Mengumpulkan lebih banyak data dari sumber lain untuk dilatih, sehingga lebih banyak ragam pola data untuk dikenali sistem.
2. Menerapkan lebih banyak metode augmentasi data, baik untuk transformasi geometrik, maupun untuk modifikasi warna, filter kernel dan lain sebagainya. Sehingga untuk data pelatihan yang sama dapat dikenali dengan banyak variasi modifikasi.
3. Menerapkan beberapa modifikasi untuk mempercepat pelatihan model dalam arsitektur CNN yang dibangun, seperti *dropout*, *inception*, dsb.

- Recognition Supported by User Interaction for Service Robots*, 1, 771–774. IEEE.
- Darmawati, D.(2010). Kanker Serviks Wanita Usia Subur. *Idea Nursing Journal*, 1(1), 09-13.
- Deverakonda, A., Gupta, N.(2016). Diagnosis and Treatment of Cervical Cancer: A Review. *J Nurs Health Sci*, 2(3).
- Devi, M. A., Ravi, S., Vaishnavi, J., dan Punitha, S. (2016). Classification of cervical cancer using artificial neural networks. *Procedia Computer Science*, 89, 465–472.
- Diananda, R. (2007). Mengenal Seluk Beluk Kanker. *Yogyakarta: Katahati*.
- Dumoulin, V., dan Visin, F. (2016). A guide to convolution arithmetic for deep learning. *ArXiv Preprint ArXiv:1603.07285*.
- Ekasari, Yunidha. (2015). Diagnosis Kanker Serviks Menggunakan Model Recurrent Neural Network (RNN) Berbasis Graphical User Interface (GUI). *Yogyakarta, Universitas Negeri Yogyakarta*.
- Garg, R., dan Desai, R. (2017). Cytologic and colposcopic evaluation of all symptomatic women at tertiary care centre. *Int J Adv Med*, 4(3), 799.
- Gonzales, R. C., dan Woods, R. E. (2002). *Digital image processing*. Prentice hall New Jersey.
- Goodfellow, I., Bengio, Y., dan Courville, A. (2016). *Deep learning*. MIT press.
- Gordon, S., Zimmerman, G., Long, R., Antani, S., Jeronimo, J., dan Greenspan, H. (2006). Content analysis of uterine cervix images: initial steps toward content

- based indexing and retrieval of cervigrams. *Medical Imaging 2006: Image Processing*, 6144, 61444U. International Society for Optics and Photonics.
- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., ... Cai, J. (2018). Recent advances in convolutional neural networks. *Pattern Recognition*, 77, 354–377.
- Gummeson, A. (2016). Prostate Cancer Classification using Convolutional Neural Networks. *Master Theses in Mathematical Sciences*.
- Hakim, R. B. F., Si, S., dan Si, M. (2018). *Penerapan Deep Learning Menggunakan Convolutional Neural Network Untuk Klasifikasi Citra Wayang Punakawan*.
- Handayani, L., Suharmiati, A. M., dan Ayuningtyas, A. (2012). *Menaklukkan Kanker Serviks Dan Kanker Payudara Dengan 3 Terapi Alami*. AgroMedia.
- He, K., Zhang, X., Ren, S., dan Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 770–778.
- Hejmadi, M. (2009). *Introduction to cancer biology*. Ventus Publishing ApS.
- Ioffe, S., dan Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. *ArXiv Preprint ArXiv:1502.03167*.
- Ji, Q., Engel, J., dan Craine, E. (2000). Texture analysis for classification of cervix lesions. *IEEE Transactions on Medical Imaging*, 19(11), 1144–1149.
- Jiang, Y., Chen, L., Zhang, H., dan Xiao, X. (2019). Breast cancer histopathological image classification using convolutional neural networks with small SE-ResNet module. *PloS One*, 14(3), e0214587.

- Munir, K., Elahi, H., Ayub, A., Frezza, F., dan Rizzi, A. (2019). Cancer Diagnosis Using Deep Learning: A Bibliographic Review. *Cancers*, 11(9), 1235.
- Murphy, K. P. (2012). *Machine learning: a probabilistic perspective*. MIT press.
- Nayak, D. R., Dash, R., dan Majhi, B. (2015). Classification of brain MR images using discrete wavelet transform and random forests. *2015 Fifth National Conference on Computer Vision, Pattern Recognition, Image Processing and Graphics (NCVPRIPG)*, (December), 1–4. <https://doi.org/10.1109/NCVPRIPG.2015.7490068>
- Nurhikmat, T. (2018). *Implementasi Deep learning Untuk Image Classification Menggunakan Algoritma Convolutional Neural Network (CNN) Pada Citra Wayang Golek*.
- Nurwijaya, H. (2010). *Kanker Serviks*. Jakarta: Elex Media Komputindo.
- Pettersson, F. (1988). Annual report on the results of treatment in gynecological cancer. *Stockholm: International Federation of Gynecology and Obstetrics*, 20, 110–151.
- Prasetyo, E. (2012). *Data Mining Konsep dan Aplikasi menggunakan MATLAB*. Yogyakarta: Andi.
- Prasetyo, E. (2014). *Data Mining Mengolah Data Menjadi Informasi Menggunakan MATLAB*. Yogyakarta: Andi.
- Primadiarti, P., dan Lumintang, H. (2018). Peran Kolposkopi dalam Mendeteksi Infeksi Menular Seksual (Role of Colposcopy in Sexual Transmitted Infection detection). *Fakultas Kedokteran Universitas Airlangga*, 23(3), 222–228.

- Pujoseno, J. (2018). *Implementasi Deep Learning Menggunakan Convolutional Neural Network untuk Klasifikasi Alat Tulis*.
- Putra, D. (2010). *Pengolahan Citra Digital*. Yogyakarta: ANDI.
- Rahman, M. A. (2019). *Sistem deteksi dini kanker payudara pada Citra Mammogram menggunakan metode Convolutional Neural Network*. UIN Sunan Ampel.
- Sasikala, S., Bharathi, M., dan Sowmiya, B. R. (2018). *Lung Cancer Detection and Classification Using Deep CNN*. (2), 259–262.
- Satyam, Jiao, Y., Ben-Or, Y., Levitz, D., dan Zimmermann, R. (2018). *Cervical Cancer Screening Through a Cloud-Based Algorithmic Analysis of Cervical Images on a Mobile Platform*.
- Sena, S. (2017). *Pengenalan Deep Learning Part 7 : Convolutional Neural Network (CNN)*. Diakses 17 Oktober 2019, dari <https://medium.com/@samuelsena/pengenalan-deep-learningpart-7-convolutional-neuralnetwork-cnn-b003b477dc94>.
- Shorten, C., dan Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6(1), 60.
- Sokolova, M., dan Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing dan Management*, 45(4), 427–437.
- Stenroos, O. (2017). *Object detection from images using convolutional neural networks*. Aalto University.
- Sukardi. (2015). *Pengolahan Citra Digital*. Makassar.

- Suryapratama, S. A., dan Pramono, B. A. (2012). *Karakteristik penderita kanker serviks di RSUP Dr. Kariadi Semarang Tahun 2010*. Fakultas Kedokteran.
- Tumer, K., Ramanujam, N., Ghosh, J., dan Richards-Kortum, R. (1998). Ensembles of radial basis function networks for spectroscopic detection of cervical precancer. *IEEE Transactions on Biomedical Engineering*, 45(8), 953–961.
- Vasudha, Mittal, A., dan Juneja, M. (2018). *Cervix Cancer Classification using Colposcopy Images by Deep Learning Method*. 5(3), 426–432.
- WHO. (2018). World Health Organization. Diakses pada 10 Oktober 2019, dari <https://www.who.int/>.
- Xu, B., Wang, N., Chen, T., dan Li, M. (2015). Empirical evaluation of rectified activations in convolutional network. *ArXiv Preprint ArXiv:1505.00853*.
- Zufar, M., dan Setiyono, B. (2016). Convolutional neural networks untuk pengenalan wajah secara real-time. *Jurnal Sains Dan Seni ITS*, 5(2).