

**TESIS**

**ANALISIS PERBANDINGAN MODEL DEEP LEARNING UNTUK  
KLASIFIKASI SAMPAH MEDIS MENGGUNAKAN TRANSFER  
LEARNING**



Disusun oleh:

**Nama : Astika Wulansari  
NIM : 20.52.1365  
Konsentrasi : Business Intelligence**

**PROGRAM STUDI S2 TEKNIK INFORMATIKA  
PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA  
YOGYAKARTA  
2022**

**TESIS**

**ANALISIS PERBANDINGAN MODEL DEEP LEARNING UNTUK  
KLASIFIKASI SAMPAH MEDIS MENGGUNAKAN TRANSFER  
LEARNING**

**COMPARATIVE ANALYSIS OF MULTIPLE DEEP LEARNING  
MODELS FOR MEDICAL WASTE CLASSIFICATION USING  
TRANSFER LEARNING**

Diajukan untuk memenuhi salah satu syarat memperoleh derajat Magister



Disusun oleh:

**Nama : Astika Wulansari**  
**NIM : 20.52.1365**  
**Konsentrasi : Business Intelligence**

**PROGRAM STUDI S2 TEKNIK INFORMATIKA**  
**PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA**  
**YOGYAKARTA**  
**2022**

## HALAMAN PENGESAHAN

**ANALISIS PERBANDINGAN MODEL DEEP LEARNING UNTUK KLASIFIKASI SAMPAH MEDIS MENGGUNAKAN TRANSFER LEARNING**

**COMPARATIVE ANALYSIS OF MULTIPLE DEEP LEARNING MODELS FOR MEDICAL WASTE CLASSIFICATION USING TRANSFER LEARNING**

Dipersiapkan dan Disusun oleh

**Astika Wulansari**

**20.52.1365**

Telah Diujikan dan Dipertahankan dalam Sidang Ujian Tesis  
Program Studi S2 Teknik Informatika  
Program Pascasarjana Universitas AMIKOM Yogyakarta  
pada hari Rabu, 3 Agustus 2022

Tesis ini telah diterima sebagai salah satu persyaratan  
untuk memperoleh gelar Magister Komputer.

Yogyakarta, 3 Agustus 2022

**Rektor**

**Prof. Dr. M. Suyanto, M.M.**  
**NIK. 190302001**

## HALAMAN PERSETUJUAN

### ANALISIS PERBANDINGAN MODEL DEEP LEARNING UNTUK KLASIFIKASI SAMPAH MEDIS MENGGUNAKAN TRANSFER LEARNING

Dipersiapkan dan Disusun oleh

**Astika Wulansari**

**20.52.1365**

Telah Diujikan dan Dipertahankan dalam Sidang Ujian Tesis  
Program Studi S2 Teknik Informatika  
Program Pascasarjana Universitas AMIKOM Yogyakarta  
pada hari Rabu, 3 Agustus 2022

Pembimbing Utama

Anggota Tim Pengaji

**Dr. Arief Setyanto, S.Si., M.T.**  
NIK. 190302036

**Prof. Dr. Ema Utami, S.Si, M.Kom.**  
NIK. 190302037

Pembimbing Pendamping

**Alva Hendi Muhammad, S.T, M, Eng, Ph.D**  
NIK. 190302493

**Emha Taufiq Luthfi, S.T., M.Kom.**  
NIK. 190302107

**Dr. Arief Setyanto, S.Si., M.T.**  
NIK. 190302036

Tesis ini telah diterima sebagai salah satu persyaratan  
untuk memperoleh gelar Magister Komputer

Yogyakarta, 3 Agustus 2022  
**Direktur Program Pascasarjana**

**Prof. Dr. Kusrini, M.Kom.**  
NIK. 190302106

## HALAMAN PERNYATAAN KEASLIAN TESIS

Yang bertandatangan di bawah ini,

**Nama mahasiswa : Astika Wulansari**  
**NIM : 20.52.1365**  
**Konsentrasi : Business Intelligence**

Menyatakan bahwa Tesis dengan judul berikut:

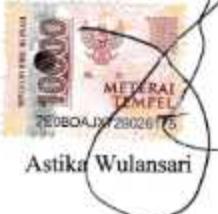
**Analisis Perbandingan Model Deep Learning Untuk Klasifikasi Sampah Medis Menggunakan Transfer Learning**

Dosen Pembimbing Utama : Dr. Arief Setyanto, S.Si., M.T.  
Dosen Pembimbing Pendamping : Emha Taufiq Luthfi, S.T., M.Kom.

1. Karya tulis ini adalah benar-benar ASLI dan BELUM PERNAH diajukan untuk mendapatkan gelar akademik, baik di Universitas AMIKOM Yogyakarta maupun di Perguruan Tinggi lainnya
2. Karya tulis ini merupakan gagasan, rumusan dan penelitian SAYA sendiri, tanpa bantuan pihak lain kecuali arahan dari Tim Dosen Pembimbing
3. Dalam karya tulis ini tidak terdapat karya atau pendapat orang lain, kecuali secara tertulis dengan jelas dicantumkan sebagai acuan dalam naskah dengan disebutkan nama pengarang dan disebutkan dalam Daftar Pustaka pada karya tulis ini
4. Perangkat lunak yang digunakan dalam penelitian ini sepenuhnya menjadi tanggung jawab SAYA, bukan tanggung jawab Universitas AMIKOM Yogyakarta
5. Pernyataan ini SAYA buat dengan sesungguhnya, apabila di kemudian hari terdapat penyimpangan dan ketidakbenaran dalam pernyataan ini, maka SAYA bersedia menerima SANKSI AKADEMIK dengan pencabutan gelar yang sudah diperoleh, serta sanksi lainnya sesuai dengan norma yang berlaku di Perguruan Tinggi

Yogyakarta, 3 Agustus 2022

Yang Menyatakan,



Astika Wulansari

STAMPA RUBRA  
METRAI TEMPAT  
26082020/15

## KATA PENGANTAR

Alhamdulillah, segala puji syukur penulis panjatkan kehadirat Allah SWT, atas segala karunia dan ridho-NYA, sehingga tesis dengan judul “Analisis Perbandingan Model Deep Learning Untuk Klasifikasi Sampah Medis Menggunakan Transfer Learning” ini dapat diselesaikan.

Tesis ini disusun untuk memenuhi salah satu persyaratan memperoleh gelar Magister Komputer (M.Kom.) dalam konsentrasi Business Intelligence pada program studi S2 Teknik Informatika Universitas Amikom Yogyakarta.

Oleh karena itu, pada kesempatan ini penulis menyampaikan rasa hormat dan menghaturkan terima kasih yang sebesar-besarnya, kepada :

1. Bapak Dr. Arief Setyanto, S.Si, M.T. atas bimbingan, arahan dan waktu yang telah diluangkan kepada penulis untuk berdiskusi selama menjadi dosen pembimbing utama dan perkuliahan serta kesediaannya mengikutsertakan penulis pada kesempatan banyak hal.
2. Bapak Emha Taufiq Luthfi, S.T., M.Kom. selaku dosen pembimbing pendamping, dan Bapak/Ibu Dosen Pengaji yang telah memberikan masukan dan saran pada saat seminar proposal, seminar hasil tesis, dan seminar tesis.
3. Seluruh Dosen Program Pascasarjana Teknik Informatika Universitas Amikom Yogyakarta yang telah memberikan arahan dan bimbingan.
4. Dinas Pendidikan dan Kebudayaan Provinsi Jawa Tengah dan SMK Negeri 5 Sukoharjo atas ijin belajar yang telah diberikan.

5. Kepada semua pihak yang telah membantu yang tidak dapat penulis sebutkan satu persatu.

Dengan keterbatasan pengalaman, ilmu maupun pustaka yang ditinjau, penulis menyadari bahwa tesis ini masih banyak kekurangan dan pengembangan lanjut agar benar benar bermanfaat. Oleh sebab itu, penulis sangat mengharapkan kritik dan saran agar tesis ini lebih sempurna serta sebagai masukan bagi penulis untuk penelitian dan penulisan karya ilmiah di masa yang akan datang.

Akhir kata, penulis berharap tesis ini memberikan manfaat bagi kita semua terutama untuk pengembangan ilmu pengetahuan yang ramah lingkungan.

Yogyakarta, 3 Agustus 2022

Penulis

## DAFTAR ISI

HALAMAN JUDUL	ii
HALAMAN PENGESAHAN	iii
HALAMAN PERSETUJUAN	iv
HALAMAN PERNYATAAN KEASLIAN TESIS	v
KATA PENGANTAR	vi
DAFTAR ISI	viii
DAFTAR TABEL	xi
DAFTAR GAMBAR	xii
INTISARI	xiv
<i>ABSTRACT</i>	xv
BAB I PENDAHULUAN	1
1.1. Latar Belakang Masalah	1
1.2. Rumusan Masalah	3
1.3. Batasan Masalah	4
1.4. Tujuan Penelitian	4
1.5. Manfaat Penelitian	5
BAB II TINJAUAN PUSTAKA	6
2.1. Tinjauan Pustaka	6

2.2. Keaslian Penelitian	14
2.3. Landasan Teori	18
2.3.1 Sampah	18
2.3.3 <i>Convolutional Neural Network (CNN)</i>	22
2.3.3.1 VGG	26
2.3.3.2 ResNet50	27
2.3.3.3 InceptionV3	29
2.3.3.4 MobileNetV2	29
2.3.4 <i>Transfer Learning</i>	30
2.3.5 <i>Confusion Matrix</i>	33
<b>BAB III METODE PENELITIAN</b>	38
3.1. Jenis, Sifat, dan Pendekatan Penelitian	38
3.2. Metode Pengumpulan Data	38
3.3. Metode Analisis Data	39
3.4. Alur Penelitian	39
<b>BAB IV HASIL PENELITIAN DAN PEMBAHASAN</b>	42
4.1. Pengumpulan Data ( <i>Raw Data</i> )	42
4.2. <i>Preprocessing</i>	44
4.3. Klasifikasi Model CNN	46

4.3.1 VGG16	47
4.3.2 VGG19	49
4.3.3 ResNet50	50
4.3.4 InceptionV3	50
4.3.5 MobileNetV2	51
BAB V PENUTUP	57
5.1. Kesimpulan	57
5.2. Saran	58
DAFTAR PUSTAKA	59
LAMPIRAN	68

## DAFTAR TABEL

Tabel 2.1 Penelitian tentang klasifikasi sampah dengan CNN berdasarkan akurasi terbaik.....	6
Tabel 2.2 Penelitian klasifikasi sampah dengan menggunakan kombinasi metode CNN .....	10
Tabel 2.3 Penelitian klasifikasi sampah dengan kombinasi CNN dan <i>transfer learning</i> .....	11
Tabel 2.4 Penelitian klasifikasi sampah medis .....	12
Tabel 2.5 Hasil Penelusuran Metode CNN .....	13
Tabel 2.6 Matriks <i>literatur review</i> dan posisi penelitian .....	14
Tabel 2.7 Matriks <i>literatur review</i> dan posisi penelitian (Lanjutan) .....	15
Tabel 2.8 <i>Confusion Matrix</i> .....	33
Tabel 3.1 Dataset sampah medis.....	38
Tabel 4. 1 Perbandingan <i>accuracy</i> dengan <i>preprocessing</i> .....	46
Tabel 4.2 Perbandingan augmentasi data.....	47
Tabel 4.3 Perbandingan <i>Confusion Matrix</i> .....	53
Tabel 4.4 Kinerja Model <i>Deep Learning</i> .....	53
Tabel 4.5 Hasil Pelatihan .....	54
Tabel 4.6 Hasil Pengujian .....	54

## DAFTAR GAMBAR

Gambar 1. Bagan jenis sampah	20
Gambar 2. Hubungan <i>deep learning</i> dengan <i>machine learning</i>	21
Gambar 3. Dimensi CNN	22
Gambar 4. Arsitektur CNN	22
Gambar 5. Ilustrasi Format RGB.	23
Gambar 6. Proses konvolusi (Medium Samuel Sena, 2017)	24
Gambar 7. <i>Max Pooling</i> (Medium Samuel Sena, 2017).	25
Gambar 8. Arsitektur VGG16 dan VGG19 (Khush Patel, 2020)	27
Gambar 9. Arsitektur ResNet50 (Khush Patel, 2020)	28
Gambar 10. Arsitektur InceptionV3 (Khush Patel, 2020)	29
Gambar 11. Arsitektur MobileNetV2 (Rizqi Okta Ekoputris, 2018)	30
Gambar 12. Augmentasi data (a) <i>random flip</i> (b) <i>random crop</i> .	36
Gambar 13. Augmentasi data (a) <i>random resize</i> (b) <i>brightness</i> .	37
Gambar 14. Blok diagram klasifikasi citra sampah medis	40
Gambar 15. Sampah infeksius (a) non tajam (b) tajam	43
Gambar 16. Gambar sebelum augmentasi.	45
Gambar 17. Gambar setelah augmentasi.	45
Gambar 18. Grafik <i>accuracy</i> dan <i>loss</i> VGG16.	48
Gambar 19. <i>Confusion matrix</i> VGG16.	48
Gambar 20. Grafik <i>accuracy</i> dan <i>loss</i> VGG19.	49
Gambar 21. <i>Confusion matrix</i> VGG19.	49

Gambar 22. Grafik <i>accuracy</i> dan <i>loss</i> ResNet50.	50
Gambar 23. <i>Confusion matrix</i> ResNet50.	50
Gambar 24. <i>Confusion matrix</i> InceptionV3.	51
Gambar 25. Grafik <i>accuracy</i> dan <i>loss</i> InceptionV3.	51
Gambar 26. Grafik <i>accuracy</i> dan <i>loss</i> MobileNetV2.	52
Gambar 27. <i>Confusion matrix</i> MobileNetV2.	52



## INTISARI

Pandemi Corona Virus Disease (COVID-19) berkembang pesat di seluruh dunia. Pengelolaan sampah dan penanganan sampah terkontaminasi yang tidak tepat dapat secara tidak sengaja menyebarkan virus di masyarakat. Klasifikasi sampah medis menggunakan deep learning mengatasi masalah pelik dari pemilihan sampah secara manual seperti melakukan kesalahan, beban kerja yang berat, serta efisiensi waktu dan biaya. Analisis perbandingan model *deep learning* untuk klasifikasi sampah medis menggunakan *transfer learning* diharapkan dapat menyediakan dataset publik sampah medis, dapat mengidentifikasi arsitektur CNN yang mampu melakukan klasifikasi sampah medis dengan kinerja yang dapat diterima, dapat mengklasifikasikan sampah medis untuk mendapatkan akurasi yang baik, kecepatan proses yang baik, dan beban komputasi yang ringan. Jenis sampah medis ada 2 (dua) kelas yaitu sampah infeksius tajam dan sampah infeksius non tajam, menggunakan *transfer learning* dengan data *pretraining* dari ImageNet. Metode analisis hasil klasifikasi dilakukan dengan penghitungan akurasi (*accuracy*), *precision*, *recall*, dan *F1-Score*.

Menggunakan augmentasi data, dan preprocessing sebelum melakukan klasifikasi penelitian ini dilakukan beberapa kali percobaan. Model ResNet50 mencapai akurasi tertinggi dan membutuhkan parameter dan kecepatan pelatihan lebih cepat dimana akurasi 99,40%, sensitivitas 98,18%, dan spesifisitas 100% tanpa *overfitting*.

Model CNN dengan transfer learning dapat melakukan klasifikasi sampah medis dengan baik. Hal ini dibuktikan dengan model VGG16 menghasilkan nilai akurasi terendah 96,39% dan nilai akurasi tertinggi dicapai model ResNet50 mencapai 99,40%. ResNet50 membutuhkan kecepatan pelatihan 946,64 detik dengan jumlah parameter 25.687.938 yang lebih kecil dari VGG16, VGG19, InceptionV3, dan MobileNetV2.

Kata kunci: *Convolutional Neural Network*, *Deep Learning*, Klasifikasi Sampah Medis, *Transfer Learning*.

## **ABSTRACT**

The Corona Virus Disease (COVID-19) pandemic is growing rapidly around the world. Improper waste management and handling of contaminated waste can inadvertently spread the virus in the community. Medical waste classification using deep learning overcomes the complex problems of manual waste sorting such as making mistakes, heavy workloads, and time and cost efficiency. Comparative analysis of deep learning models for medical waste classification using transfer learning is expected to provide a public dataset of medical waste, can identify a CNN architecture capable of classifying medical waste with acceptable performance, can classify medical waste to get good accuracy, good processing speed, and light computing load. There are 2 (two) classes of medical waste, namely sharp infectious waste and non-sharp infectious waste, using transfer learning with pretraining data from ImageNet. The method of analysis of classification results is carried out by calculating accuracy, precision, recall, and F1-Score.

Using data augmentation, and preprocessing before doing the classification, this research was carried out several times. The ResNet50 model achieves the highest accuracy and requires faster training parameters and speed where accuracy is 99.40%, sensitivity is 98.18%, and specificity is 100% without overfitting.

The CNN model with transfer learning can classify medical waste well. This is evidenced by the VGG16 model producing the lowest accuracy value of 96.39% and the highest accuracy value achieved by the ResNet50 model reaching 99.40%. ResNet50 requires a training speed of 946.64 seconds with a number of parameters of 25,687,938 which is smaller than VGG16, VGG19, InceptionV3, and MobileNetV2.

**Keyword:** Convolutional Neural Network, Deep Learning, Medical Waste Classification, Transfer Learning.

## **BAB I**

### **PENDAHULUAN**

#### **1.1. Latar Belakang Masalah**

Pandemi Covid-19 yang berkepanjangan di dunia menimbulkan sampah medis berbahaya yang tidak terkelola. Hingga kini jumlahnya mencapai 20.000 ton/kubik. Sampah medis ini masuk kategori bahan berbahaya dan beracun (B3). Sampah medis berasal dari fasilitas pelayanan kesehatan, vaksinasi covid-19, pusat isolasi mandiri, pemeriksaan rapid tes covid-19 dan berasal dari rumah tangga. Fasilitas pengelolaan sampah B3 masih terbatas, maka kondisi penanganan sampah B3 dalam kondisi darurat. Jika sampah tidak ditangani dengan baik, masalah lingkungan akan semakin meningkat dalam jangka panjang yang akan menjadi hambatan terbesar pembangunan berkelanjutan. Dari sistem pengelolaan sampah medis yang masuk ke tempat pembuangan akhir (TPA) diperkirakan orang yang berhubungan langsung dengan limbah medis berisiko untuk terkena infeksi covid-19 (Bian dkk., 2021).

Salah satu langkah penting dalam pengelolaan sampah adalah pemisahan sampah ke dalam komponen yang berbeda dan proses ini biasanya dilakukan manual dengan tangan (Adedeji & Wang, 2019). Klasifikasi sampah mengatasi masalah pelik dari pemilihan sampah secara manual seperti melakukan kesalahan, beban kerja yang berat, serta efisiensi waktu dan biaya (Q. Zhang, Yang, dkk., 2021). Sampah medis dapat menjadi rantai penularan virus. sampah ini sangat berbahaya bagi kesehatan dan lingkungan karena mengandung banyak

mikroorganisme patogen berupa virus, bakteri, jamur, dan parasit. Maka diperlukan alat yang mampu secara otomatis melakukan klasifikasi sampah.

Sampah medis terdiri dari 2 kategori yaitu sampah infeksius dan non infeksius. Sampah infeksius adalah sampah dari hasil aktivitas unit pelayanan kesehatan yang membahayakan dan dapat menimbulkan gangguan kesehatan masyarakat, pengunjung, dan petugas yang menangani. Sedangkan sampah non infeksius adalah sampah yang dihasilkan dari kegiatan manusia yang dirasakan tidak berguna dan dapat mengganggu manusia dan lingkungannya. Sampah infeksius terdiri dari dua wujud yaitu padat dan cair. Untuk sampah infeksius padat memiliki 2 kategori yaitu tajam dan non tajam. Sampah infeksius padat kategori tajam itu seperti jarum (suntik dan jahit), dan botol kaca/vial. Sedangkan sampah infeksius padat kategori non tajam seperti alat pelindung diri (APD) meliputi masker, handscoon, apron, cover shoes, head cap), botol infus plastik, dan badan suntik.

*Computer vision* dan *deep learning* mampu membantu dalam deteksi otomatis dan klasifikasi jenis sampah untuk daur ulang (Mao dkk., 2021). Deep learning salah satu bagian kecerdasan artifisial yang dapat menyelesaikan masalah klasifikasi melalui citra dan *Convolutional Neural Network* (CNN) merupakan salah satu arsitektur *deep learning* yang paling dominan untuk pengolahan citra. Beberapa model CNN yang diadopsi dari eksperimen sebelumnya antara lain AlexNet (Toğaçar dkk., 2020), VGG (Huang dkk., 2020), ResNet (Meng & Chu, 2020), dan DenseNet (Q. Zhang, Yang, dkk., 2021). Penerapan CNN dengan transfer learning akan fokus pada transfer parameter model CNN yang baru dan

meningkatkan akurasi (Rismiyati dkk., 2020), dapat diterapkan pada gabungan model CNN untuk klasifikasi sampah (Huang dkk., 2020), melakukan klasifikasi sampah dengan lebih cepat (Y. Chen dkk., 2021).

Penelitian sebelumnya tentang klasifikasi citra sampah medis menggunakan dataset OpenCV dan SSD-MobileNet (Bian dkk., 2021), dan melakukan klasifikasi sampah berdasarkan video yang direkam dengan kombinasi metode 2D CNN dan 3D CNN (J. Chen dkk., 2020). Penelitian ini merupakan penelitian pendahuluhan sebagai upaya menuju otomatisasi klasifikasi sampah pada perangkat berdaya komputasi kecil seperti raspberry Pi, jetsen nano dan lain sebagainya. Fokus penelitian ini adalah computer vision dengan mencari arsitektur CNN dengan nilai akurasi yang masih bisa diterima, waktu yang diperlukan pendek, membutuhkan perangkat yang relatif ringan pada klasifikasi sampah medis dengan pengambilan gambar dari beberapa fasilitas pelayanan kesehatan dan internet. Penelitian ini juga berkontribusi dalam menyediakan dataset sampah medis dengan 2 kelas tajam dan non tajam yang diambil dari pusat kesehatan dalam kurun waktu 1 Desember 2021 sampai dengan 31 Januari 2022.

## 1.2. Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan, maka dapat dirumuskan permasalahan yang meliputi:

1. Apakah model *deep learning* dengan *transfer learning* dapat melakukan klasifikasi sampah medis?

2. Bagaimana perbandingan kinerja antara beberapa model *deep learning* dengan *transfer learning* dalam klasifikasi sampah medis?

### 1.3. Batasan Masalah

Agar pembahasan dalam penelitian ini tidak menyimpang dari tujuan penelitian, maka dibuat batasan-batasan sebagai berikut:

1. Jenis sampah medis infeksius padat kategori tajam dan non tajam yang diusulkan oleh peneliti yang diambil dari fasilitas pelayanan kesehatan dengan kriteria sampah medis yang memiliki penanganan atau pengelolaan yang sama.
2. Dalam *transfer learning*, data pretraining mengambil dari ImageNet dan data *fine tuning* menggunakan dataset yang diusulkan oleh peneliti.
3. Analisis hasil klasifikasi dilakukan dengan penghitungan akurasi (*accuracy*), *precision*, *recall*, dan *F1-score*.

### 1.4. Tujuan Penelitian

Tujuan dari penelitian ini adalah sebagai berikut:

1. Menyediakan dataset publik sampah medis.
2. Mengidentifikasi arsitektur CNN yang mampu melakukan klasifikasi sampah medis dengan kinerja yang dapat diterima.
3. Mengklasifikasikan sampah medis untuk mendapatkan akurasi yang baik, kecepatan proses yang baik, dan beban komputasi yang ringan.

### 1.5. Manfaat Penelitian

Manfaat dari penelitian ini adalah sebagai langkah awal dalam menerapkan pengelolaan sampah medis secara otomatis untuk menentukan alternatif penanganannya. Selain itu juga sebagai referensi penggunaan *transfer learning* dengan arsitektur CNN dalam klasifikasi sampah medis.



## BAB II

### TINJAUAN PUSTAKA

#### 2.1. Tinjauan Pustaka

Beberapa penelitian tentang klasifikasi sampah dengan database digital yang dipilih adalah IEEE Xplore ([ieeexplore.ieee.org](http://ieeexplore.ieee.org)), ScienceDirect ([sciencedirect.com](http://sciencedirect.com)), ACM Digital Library ([dl.acm.org](http://dl.acm.org)), Springer ([springerlink.com](http://springerlink.com)), dan sumber lain seperti [onlinelibrary.wiley.com](http://onlinelibrary.wiley.com), [cs229.stanford.edu](http://cs229.stanford.edu), [arxiv.org](http://arxiv.org) yang sudah dilakukan dalam kurun waktu 5 (lima) tahun terakhir dapat dilaporkan sebagai berikut.

Pada Tabel 2.1 penelitian tentang klasifikasi sampah berdasarkan hasil yang terbaik. Metode yang digunakan pada tabel 2.1 masih beragam dan menggunakan berbagai macam sumber dataset. Akurasi tertinggi dicapai 99,6% dengan DenseNet121 dengan klasifikasi sampah karton, kaca, logam, plastik, dan kertas (Mao dkk., 2021).

Tabel 2.1 Penelitian tentang klasifikasi sampah dengan CNN berdasarkan akurasi terbaik

Referensi	Metode	Dataset	Jenis Sampah	Akurasi
(Mao dkk., 2021)	DenseNet 121	Trash Net	Karton, Kaca, Logam, Kertas, Plastik sampah	99,6%
(Bobulski & Kubanek, 2019)	AlexNet	Wadabu	PS, PP, PE-HD, dan PET	99,23%
(Tehrani & Karbasi, 2017)	<i>Multi layer Artificial Neural Network (ANN)</i>	Scan Camera	Sampah plastik PC, ABS, dan HIPS	99%

Tabel 2.1 Penelitian tentang klasifikasi sampah dengan CNN berdasarkan akurasi terbaik (Lanjutan)

Referensi	Metode	Dataset	Jenis Sampah	Akurasi
(Chu dkk., 2018)	Multilayer Hybrid System (MHS), dan CNN	Scan Camera	Kertas, plastik, logam, kaca, dan sampah buah/sayur/tanaman	98,5%
(Thokairak dkk., 2020)	CNN, SSD Mobile-Net	Camera	botol plastik, botol kaca, dan kaleng logam	95%, 82%, 86%
(Q. Zhang, Zhang, dkk., 2021)	ResNet18	Trash Net	kardus, kaca, logam, kertas, plastik, dan sampah	95,87%
(Song dkk., 2020)	Convolutional dan residual network (DSCR-Net)	Search engine	Sampang daur Ulang, sampah Organik, sampah berbahaya, sampai rusak.	94,3%
(C. Wang dkk., 2021)	Mobile-Net V3	Trash Net	sampai dapur, sampah BL, plastik, kaca, kertas atau kardus, logam, kain, dan sampah daur ulang lainnya	94,26%
(Aziz dkk., 2020)	CNN model Inception-v3	ImageNet	karton, kaca, logam, kertas, plastik dan lain-lain	92,5%
(Huiyu dkk., 2019)	ANN	Garbage in Images (GINI)	Kaca, plastik, kaleng, keramik dan sampah lainnya	87,6%
(Adeleji & Wang, 2019)	ResNet-50, dan SVM	Trash Image	Kaca, kertas, plastik, dan logam	87%
(Kampttiney dkk., 2018)	CNN	ISPRS Vaihingen, ISPRS Potsdam 2-D semantic labeling benchmark	Permukaan, bangunan, vegetasi rendah, pohon, mobil, dan background.	86,4%
(Frost dkk., 2019)	CNN, ComposNet Version A dan Version B	Trash Net	Sampah, Daur ulang, dan Kompos	77,3% & 22,7%
(Pamintuan dkk., 2019)	Machine learning + Inception V3	automatic waste segregator	Biodegradable : Karton, Kertas, Sampah Organik, Non-biodegradable: Botol Kaca, Pecahan Kaca, Kaleng Aluminium, Peralatan Plastik, Plastik.	75%
(Li dkk., 2020)	Mask Scoring RCNN	Coco	Sampah berbahaya, sampah dapur, sampah daur ulang, sampah lainnya	65,8%
(Altikat dkk., 2021)	Deep convolutional neural networks	Camera	Plastik, kaca, organik, dan kertas	61,67%

Tabel 2.1 Penelitian tentang klasifikasi sampah dengan CNN berdasarkan akurasi terbaik (Lanjutan)

Referensi	Metode	Dataset	Jenis Sampah	Akurasi
(Ahmed dkk., 2020)	CNN, LSTM	Social media + benchmark	Kardus, kaca, logam, kertas, plastik, dan sampah	3,1% - 4%
(Awe dkk., t.t.)	Faster-RCNN	Pascal VOC	Kertas pembuangan dan daur ulang	mAP 0,683
(Nandhini dkk., 2019)	CNN - Lenet-5	Camera	biodegradable atau non biodegradable	-
(Behera dkk., 2020)	YOLOv3 (You Only Look Once)	Camera	biodegradable, dan non biodegradable	-
(Lengo dkk., 2021)	CNN	Camera	kaca, kertas, plastik/logam, dan tidak disortir.	-

Dari tabel 2.1 didapatkan hasil penelusuran bahwa klasifikasi sampah banyak diselesaikan dengan *artificial neural network* (ANN) hingga CNN dengan menggunakan berbagai macam sumber dataset. Dataset yang dibangun sendiri juga bekerja secara optimal dengan hasil akhir sebesar 92,4% (Y. Wang dkk., 2020). InceptionV3 bekerja dengan baik hingga akurasi 92,5% (Azis dkk., 2020) menggunakan ImageNet. Model InceptionV3 memberikan probabilitas bahwa data gambar masukan milik masing-masing dari enam jenis limbah; dengan jenis sampah dengan probabilitas tertinggi mewakili klasifikasi input data gambar dari model namun mampu memisahkan jenis sampah *biodegradable* dan *non-biodegradable* dengan akurasi 75% (Pamintuan dkk., 2019) dengan menggunakan pemilah sampah otomatis dan sistem pemantauan dengan bantuan IoT untuk membantu memperkenalkan teknologi dalam sistem pengelolaan sampah negara.

Klasifikasi botol plastik, botol kaca, dan kaleng logam mendapatkan hasil akurasi 95% botol plastik, klasifikasi botol kaca 82%, dan akurasi kaleng logam 86% menjalankan TensorFlow yang terintegrasi dengan SSD MobileNet (Thokrairak dkk., 2020). MobileNet dengan TrashNet mencapai akurasi 92,65% (H. Wang dkk., 2020) dalam klasifikasi sampah organik, sampah yang tidak dapat didaur ulang, dan sampah yang dapat didaur ulang.

Penelusuran selanjutnya fokus pada penelitian dimana menggunakan kombinasi algoritma CNN untuk mendapatkan akurasi yang baik dalam klasifikasi sampah. Kombinasi algoritma yang dilakukan sebagai upaya untuk meningkatkan akurasi dalam melakukan klasifikasi sampah. Akurasi terbaik yang dicapai 99,37% dengan menggunakan metode kombinasi antara AlexNet, GoogLeNet, ResNet-50 (Toğaçar dkk., 2020). Beberapa hasil baik dicapai algoritma VGG16 (H. Wang dkk., 2020), VGG19 (Ruiz dkk., 2019), ResNet (Gyawali dkk., 2020), dan MobileNetV2 (Sheng dkk., 2020). Klasifikasi sampah menggunakan VGG16 dengan hasil terbaik, akurasi 83,2% (Abela & Gatt, 2021) dan akurasi 87,41% (H. Wang dkk., 2020) dengan TrashNet (Gyawali dkk., 2020). VGG16 hanya mampu memprediksi kelas yang benar sedikit dibandingkan dengan ResNet50 (Rismiyati dkk., 2020). Hasil penelusuran klasifikasi sampah dengan melakukan kombinasi berbagai algoritma CNN seperti pada tabel 2.2.

Untuk mencapai akurasi klasifikasi yang lebih baik, biasanya menggunakan sejumlah besar data berlabel untuk melatih model untuk mendapatkan parameter yang optimal (Huang dkk., 2020). Karena proses pelatihan model CNN membutuhkan banyak sumber daya (termasuk sejumlah

besar dataset dan waktu komputasi), *transfer learning* diperkenalkan untuk membangun model klasifikasi sampah. Penelusuran selanjutnya adalah dengan menambahkan *transfer learning* dalam memanfaatkan pengetahuan yang diperoleh *deep learning* pada tugas sebelumnya untuk menyelesaikan tugas serupa.

Tabel 2.2 Penelitian klasifikasi sampah dengan menggunakan kombinasi metode CNN

Referensi	Metode	Dataset	Jenis Sampah	Akurasi
(Togucar dkk., 2020)	AlexNet, GoogLeNet, ResNet-50, dan RR Feature Selection	Google images and ImageNet web sites	organic dan recyclable	99,37%
(Delnevo dkk., 2021)	CNN - DenseNet121, CNN1: DenseNet121 - Dense - output, CNN2: DenseNet121 - SVM - Output	Trash Net	Kaca, kertas, karton, plastik, logam, dan sampah lainnya	CNN 1 : 95,2% CNN 2 : 98,6%
(Meng & Chu, 2020)	SVM (HOG feature, Simple CNN, ResNet) dan CNN dan HOG feature	Kaggle	sampah kardus, kaca, logam, kertas, plastik, dan sampah lainnya	95,15%
(S. Zhang, Chun, dkk., 2021)	RevM, the ClfM-VGG, the ClfM-AlexNet, the ClfM-ResNet, the ClfM-ResNeXt, and the MS	Computer Vision Module	Sampah daur ulang, Sampah sisa, Sampah makanan rumah tangga, Sampah berbahaya	94,71%
(H. Wang dkk., 2020)	CNN architectures (VGG16, ResNet, MobileNet, InceptionNet, and DenseNet)	Trash Net	sampah organik, sampah non daur ulang, dan sampah daur ulang	92,6%
(Ruiz dkk., 2019)	VGG16, VGG19, dan ResNet	Trash Net	Sampah plastik, logam, kardus, kertas, kaca	88,66%
(Gyawali dkk., 2020)	ResNet50, VGG16, dan ResNet18	Trash Net	Kaca, kertas, plastik, dan logam	87,8%
(Sheng dkk., 2020)	VGG16, ResNet50, MobileNetV2, and DenseNet121	Trash Net	Logam, kertas, plastik, dan lainnya	85%

Tabel 2.2 Penelitian klasifikasi sampah dengan menggunakan kombinasi metode CNN (Lanjutan)

Referensi	Metode	Dataset	Jenis Sampah	Akurasi
(Abela & Gatt, 2021)	VGG, ResNet, MobileNet dan DenseNet	Trash Net, MINC	Logam, kertas, plastik, dan Makanan	83.2%

Penelitian klasifikasi sampah pada tabel 2.3 adalah penelitian dengan memanfaatkan *transfer learning* pada algoritma CNN. VGG16, ResNet-50 and Xception dengan *transfer learning* mampu mencapai 95,8% dalam melakukan klasifikasi sampah dengan menggunakan dataset *Trash Net* (Rismiyati dkk., 2020). Transfer learning dengan VGG19 mencapai akurasi 89,7% (Huang dkk., 2020) menggunakan ImageNet. Akurasi 79,32% (Ruiz dkk., 2019) menggunakan TrashNet di mana peningkatan kedalaman lapisan konvolusi memberikan hasil yang sedikit lebih baik.

Tabel 2.3 Penelitian klasifikasi sampah dengan kombinasi CNN dan *transfer learning*

Referensi	Metode	Dataset	Jenis Sampah	Akurasi
(Rismiyati dkk., 2020)	VGG16, ResNet-50 and Xception + transfer learning	Trash Net	Kaleng, botol, kotak susu, cangkir kertas, kertas dan baterai	95,8%
(Huang dkk., 2020)	VGG19, DenseNet169, dan NasNet Large + Transfer learning	Camera	Kaleng, buku, dan plastik	89,7%
(Jha dkk., 2021)	VGG16 or VGG19, InceptionV3	Kaggle	E-Commerce Product	88%
(Q. Zhang, Yang, dkk., 2021)	CNN DenseNet169, AlexNet, VGG, dan GoogleNet + transfer learning	NWNU-TRASH	Kaca, kain, kertas, plastik, dan logam	82,80%
(Y. Chen dkk., 2021)	Kombinasi ResNet50 + RPN, MobileNet V2+RPN, dan (SSD)	Camera	Logam, kertas, kaca, plastik, dan kain	-

Resnet50 dengan *transfer learning* berfungsi dengan baik menggunakan TrashNet mendapatkan akurasi 95,88% (Rismiyati dkk., 2020). Selain itu VGG16

(Jha dkk., 2021), VGG19 (Huang dkk., 2020), dan InceptionV3 (Jha dkk., 2021) yang dikombinasikan dengan *transfer learning* dapat bekerja dengan baik dalam melakukan klasifikasi sampah.

Penelusuran selanjutnya adalah penelitian ini berangkat dari sampah yang dihasilkan selama pandemi Covid-19 seperti yang telah dipaparkan pada latar belakang masalah. Sampah medis belum banyak tersedia datasetnya. Penelitian pada tabel 2.4 menggunakan dataset yang dibangun sendiri menggunakan video.

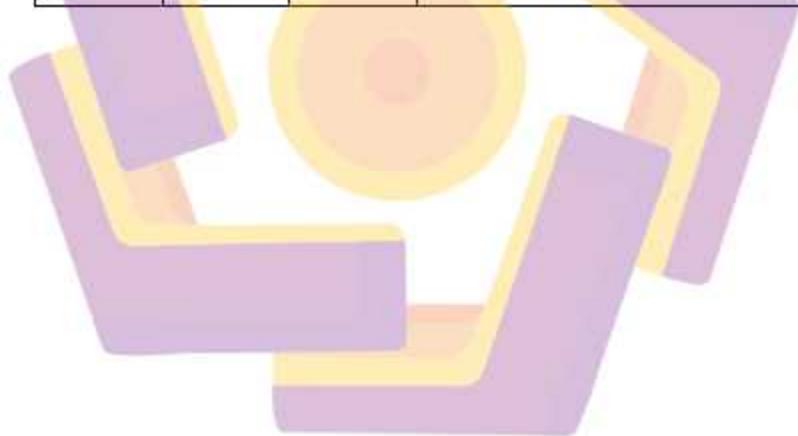
Tabel 2.4 Penelitian klasifikasi sampah medis

Referensi	Metode	Dataset	Jenis Sampah	Akurasi
(Bian dkk., 2021)	SSD-MobileNet	Scan Camera	Jarum Suntik, Tas Infus, Forceps Hemostatik, Sarung Tangan	98,5%
(J. Chen dkk., 2020)	R3D+C2D	Video	Sarung tangan, hairnet, masker, dan penutup sepatu	79,9%

Dari penelusuran penelitian terdahulu, beberapa model CNN yang digunakan maka dipilih model CNN dengan kriteria sebagai berikut : akurasi terbaik berarti hasil prediksi dengan tertinggi, akurasi terburuk adalah hasil prediksi dengan nilai terendah dari penelitian yang memiliki karakteristik dataset yang terkontrol yaitu satu gambar dengan latar belakang bersih. Berdasarkan kriteria tersebut diperoleh model CNN yang digunakan dalam penelitian ini agar mendapatkan akurasi, presisi, dan *recall* yang terbaik.

Tabel 2.5 Hasil Penelusuran Metode CNN

Metode	Akurasi Terbaik	Akurasi Terburuk	Referensi
VGG16	98,42%	84,16%	(Gyawali dkk., 2020), (H. Wang dkk., 2020), (Jha dkk., 2021), (Rismiyati dkk., 2020), (Ruiz dkk., 2019), (Sheng dkk., 2020)
VGG19	92,64%	89,7%	(Huang dkk., 2020), (Jha dkk., 2021), (Ruiz dkk., 2019)
ResNet50	97,33%	85,54%	(Adedele & Wang, 2019), (Gyawali dkk., 2020), (Jha dkk., 2021), (Rismiyati dkk., 2020), (Toğuşar dkk., 2020), (Sheng dkk., 2020)
InceptionV3	93,7%	78,75%	(Huang dkk., 2020), (Jha dkk., 2021), (Purnintuan dkk., 2019)
MobileNetV2	94,12%	84,50%	(Abela & Gait, 2021), (C. Wang dkk., 2021), (Y. Chen dkk., 2021), (Sheng dkk., 2020)



## 2.2. Keaslian Penelitian

Tabel 2.6 Matriks *literatur review* dan posisi penelitian

### Klasifikasi Sampah Menggunakan *Deep Learning*

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
1.	<i>A novel integration of hyper-spectral imaging and neural networks to process waste electrical and electronic plastics</i>	Alimohammad Tehrani and Hamidreza Karbasi; IEEE Conference on Technologies for Sustainability (SusTech); 2017	Menggunakan <i>Artificial Neural Network</i> (ANN) untuk klasifikasi sampah plastik PC, ABS, dan HPS	ANN dapat melakukan klasifikasi 3 jenis plastik dengan akurasi 99%.	Algoritma yang digunakan ANN dan jenis sampah yang dikelasifikasikan sampah plastik	Penelitian ini menggunakan arsitektur CNN dengan klasifikasi sampah yang sesuai di masa pandemi Covid-19
2	<i>Final Report: Smart Trash Net: Waste Localization and Classification</i>	Oluwasanya Awe, Robel Mengistu, Vikram Sreedhar; <a href="http://www.cs239.stanford.edu">www.cs239.stanford.edu</a> ; 2017	Menyempurnakan model Faster R-CNN yang telah dilatih sebelumnya dengan memodifikasi lapisan fully connected yang terakhir – 'cls score' dan 'bboxpred'.	Nilai mAP 0.683 pada klasifikasi gambar sampah.	Membutuhkan banyak waktu dan kinerja CPU. Menggunakan latar belakang putih cenderung mirip sampah kertas, sehingga akurasi kategori kertas buruk.	Penelitian ini menggunakan arsitektur CNN dengan klasifikasi sampah yang sesuai di masa pandemi Covid-19

Tabel 2.7 Matriks literatur review dan posisi penelitian (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
3	<i>Multilayer Hybrid Deep-Learning Method for WasteClassification and Recycling</i>	Yinghao Chu, Chen Huang, Xiaodan Xie, Bohai Tan, Shyam Kumar, Xiaogang Xiong; Computational Intelligence and Neuroscience Volume 2018, Article ID 5060857, 9 pages; 2018	Sistem pembelajaran mendalam berbasis multilayer (MHS) untuk secara otomatis memilah sampah yang dibuang oleh individu di area publik perkotaan. Sistem menyebarkan kamera resolusi tinggi untuk menangkap gambar limbah dan sensor untuk mendeteksi fitur berguna lainnya informasi. Total 100 gambar RGB diambil untuk masing-masing item yang diselidiki, dan total 5000 ( $50 \times 100$ ) gambar adalah dikumpulkan dalam format JPG.	Model MHS mencapai akurasi 98,5%, 97,1% hingga 88,6%, 85,9%. MHS sangat sensitif dalam mengidentifikasi sampah. Model CNN mencapai presisi 87,7%, 80,0% hingga 96,8%, 89,2%.	Diusulkan MHS dalam meningkatkan efisiensi klasifikasi sampah dan efektivitas. Dalam mempertimbangkan terus meningkatnya volume sampah secara global dan kebutuhan mendesak untuk pengolahan limbah sampah.	Penelitian ini menggunakan arsitektur CNN dengan klasifikasi sampah yang sesuai di masa pandemi Covid-19
4	<i>Urban Land Cover Classification With Missing Data Modalities Using Deep Convolutional Neural Networks</i>	Michael Kampffmeyer, Robert Jenssen; IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing (Volume: 11, Issue: 6, June 2018); 2018	Model CNN dalam klasifikasi permukaan, bangunan, vegetasi rendah, pohon, mobil, dan background.	Akurasi model RG+I, RG+I ensemble + hallucination -MFB 85,20% Akurasi RG + I, RG + I ensemble + hallucination - MFB 86,22%	Teknik ini membutuhkan semua modalitas untuk tersedia untuk pengklasifikasi dalam proses pengambilan keputusan, yaitu, pada pengujian waktu, serta dalam pelatihan.	Penelitian ini menggunakan arsitektur CNN dengan klasifikasi sampah yang sesuai di masa pandemi Covid-19

Tabel 2.7 Matriks *literatur review* dan posisi penelitian (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
5	<i>Intelligent Waste Classification System Using Deep Learning Convolutional Neural Network</i>	Olugboju Adedejì, Zenghui Wang; 2nd International Conference on Sustainable Materials Processing and Manufacturing (SMPM); 2019	Pemisahan sampah ke dalam komponen yang berbeda dan proses ini biasanya dilakukan secara manual dan mengklasifikasikan sampah ke dalam kelompok kaca, logam, kertas, dan plastik. Terdiri dari 1989 gambar ukurannya menjadi 512 x 384.	Support Vector Machine (SVM) untuk mengklasifikasikan sampah seperti kaca, logam, kertas, dan plastik dengan akurasi 87%	Menambah dataset, Klasifikasi dengan lebih banyak kategori dengan menjalankan beberapa parameter.	Penelitian ini menggunakan arsitektur CNN dengan klasifikasi sampah yang sesuai di masa pandemi Covid-19
6	<i>Automatic Image-Based Waste Classification</i>	Victoria Ruiz, Angel Sánchez, José F. V. Pérez, Bogdan Raducanu; International Work-Conference on the Interplay Between Natural and Artificial Computation IWINAC; 2019	klasifikasi otomatis jenis sampah terdiri dari 2.527 gambar: 501 kaca, 594 kertas, 403 karton, 482 plastik, 410 logam dan 137 sampah umum resolusi 512x384 pixel dataset TrashNet.	Paling stabil, membutuhkan epoch yang lebih sedikit untuk training. ResNet memiliki akurasi dan kecepatan yang terbaik.	Menambah jumlah model dengan berbagai macam gambar sintesis realistik kemudian menguji dengan gambar nyata.	Penelitian ini menggunakan arsitektur CNN dengan klasifikasi sampah yang sesuai di masa pandemi Covid-19
7	<i>Waste classification using Auto Encoder network with integrated feature selection method in convolutional neural network models</i>	Mesut Togluçara, Burhan Ergenb, Zafer Çömert; <a href="http://www.elsevier.com/locate/measurement">www.elsevier.com/locate/measurement</a> ; 2020	Kombinasi pemilihan fitur dan model AutoEncoder untuk kelas mengklasifikasikan dua jenis limbah yang berbeda disusulkan. Dataset yang digunakan dalam penelitian ini terdiri dari 25.077 citra sampah	AlexNet 95,39%, GoogLeNet 95,77%, dan ResNet-50 96,11%. AlexNet + GoogLeNet + ResNet + AutoEncoder + RR 99,95%	Memerlukan kumpulan data multi-kelas menggunakan modul perhatian di CNN.	Penelitian ini menggunakan arsitektur CNN dengan klasifikasi sampah yang sesuai di masa pandemi Covid-19

Tabel 2.7 Matriks *literatur review* dan posisi penelitian (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
8	<i>Smartphone-based bulky waste classification using convolutional neural networks</i>	Hanxiang Wang, Yanfen Li, L. Minh Dang, Jaesung Ko, Dongil Han, Hyun Joon Moon; Multimedia Tools and Applications volume 79, pages 29411–29431; 2020	Menggunakan CNN architectures (VGG-16, ResNet, Mobile-Net, Inception-Net, and Dense-Net) dalam klasifikasi sampah organic, non-recyclable, dan recyclable.	VGG-16 87.41%, Dense-Net 91.36%, InceptionNet 86.71%, Mobile-Net 92.65%, Res-Net 91.38%	Dataset yang digunakan penelitian ini terlalu besar untuk disebut efisien.	Penelitian ini menggunakan arsitektur CNN dengan klasifikasi sampah yang sesuai di masa pandemi Covid-19
9	<i>Waste image classification based on transfer learning and convolutional neural network</i>	Qiang Zhang, Qifan Yang, Xujian Zhang, Qiang Bao, Jinqi Su, Xueyan Liu; Waste Management Volume 135, November 2021, Pages 150-157; 2021	Model klasifikasi gambar CNN: DenseNet169, AlexNet, GoogLeNet, VGG	DenseNet169 + TL 82.80%, dibandingkan AlexNet, GoogleNet, VGG	Menggabungkan metode transfer learning sehingga model dapat lebih efektif mengidentifikasi jenis limbah.	Penelitian ini menggunakan arsitektur CNN dengan klasifikasi sampah yang sesuai di masa pandemi Covid-19
10	<i>Medical Waste Classification System Based on OpenCV and SSD-MobileNet for 5G</i>	Xiaoxiao Bian, Yuchao Chen, Shuyi Wang, Fengyi Cheng, Haotong Cao; IEEE Wireless Communications and Networking Conference Workshops (WCNCW); 2021	Sistem klasifikasi sampah berdasarkan OpenCV dan SSD-Mobile Net dibagi menjadi dua bagian: mencari objek dengan OpenCV dan mengenali objek dengan SSD-Mobile Net.	Sistem klasifikasi jarum suntik, forsep hemostatik, tas infus dan sarung tangan, NS akurasi 98,5%.	Algoritma pengurangan latar belakang background yang ada dari OpenCV.	Penelitian ini menggunakan arsitektur CNN dengan klasifikasi sampah yang sesuai di masa pandemi Covid-19

## 2.3. Landasan Teori

### 2.3.1 Sampah

Sampah adalah barang sisa yang terbuang karena sudah tidak terpakai dan tidak mempunyai nilai tetapi masih bisa dilakukan daur ulang untuk menjadi bahan yang berguna bagi manusia bahkan mempunyai nilai tinggi jika sampah bisa dikelola dengan baik. Berdasarkan sumbernya, sampah berasal dari pemukiman penduduk, tempat umum, sarana pelayanan masyarakat, perindustrian, dan pertanian. Jenis sampah secara umum dibagi menjadi 3 (tiga) yaitu sampah organik, sampah anorganik, dan sampah B3 (Ruiz dkk., 2019).

#### 1. Sampah Organik

Sampah organik adalah sampah yang dihasilkan dari makhluk hidup (manusia, hewan, dan tumbuhan) yang sifatnya mudah busuk dan mudah terurai bakteri. Berdasarkan sifatnya sampah organik dibedakan menjadi:

- a. Sampah organik padat. Sampah yang bersifat padat baik bentuk atau fisiknya. Contoh kotoran manusia atau hewan, atau sisa sayuran.
- b. Sampah organik cair. Sampah yang memiliki bentuk fisik cair dan dapat mengalir. Contohnya air seni yang dikeluarkan oleh manusia atau hewan.
- c. Sampah organik gas. Sampah yang memiliki bentuk gas. Contohnya ketika manusia atau hewan buang angin dimana menghasilkan gas metana.

#### 2. Sampah Anorganik

Sampah yang berasal selain dari makhluk hidup dan sulit diuraikan

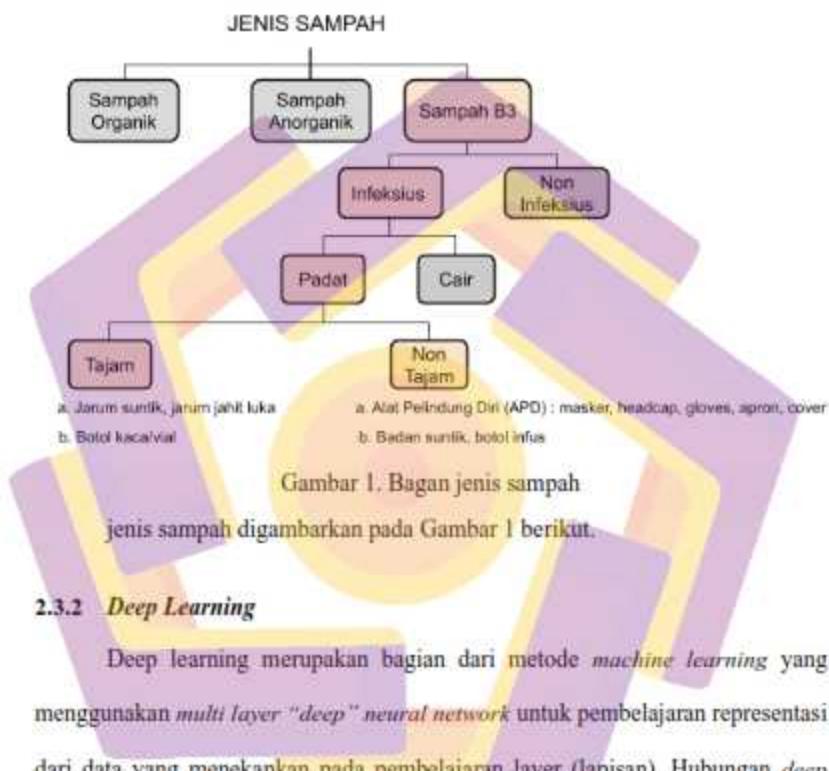
oleh tanah. Contoh plastik, kaleng, kaca, atau besi. Sampah seperti ini membutuhkan waktu yang lama untuk menguraikannya.

### 3. Sampah Bahan Beracun dan Berbahaya (B3)

Sampah B3 adalah sisa usaha atau kegiatan yang mengandung zat atau komponen yang secara langsung atau tidak langsung dapat mencemarkan, merusak, dan membahayakan lingkungan hidup, kesehatan, serta kelangsungan hidup manusia dan makhluk lainnya. Sampah B3 mengandung zat atau bahan anorganik berbahaya yang bersifat teratogenik. Mengingat sifatnya yang berbahaya dan beracun, pengelolaan sampah B3 wajib melakukan penyimpanan, pengumpulan, pengangkutan, pemanfaatan, pengolahan, dan penimbunan. Untuk memastikan pengelolaan sampah B3 dilakukan dengan tepat dan mempermudah pengawasan, pengelolaan sampah B3 wajib memiliki izin sesuai dengan peraturan yang berlaku (Irawansyah Putra & Setyowati, 2019).

Sampah medis merupakan contoh dari sampah B3. Sampah medis dibagi menjadi 2 (dua) yaitu sampah infeksius dan non infeksius. Sampah infeksius adalah sampah dari hasil aktivitas unit pelayanan kesehatan yang membahayakan dan dapat menimbulkan gangguan kesehatan masyarakat, pengunjung, dan petugas yang menangani. Sedangkan sampah non infeksius adalah sampah yang dihasilkan dari kegiatan manusia yang dirasakan tidak berguna dan dapat mengganggu manusia dan lingkungannya. Sampah infeksius terdiri dari dua wujud yaitu padat dan cair. Untuk sampah infeksius padat memiliki 2 kategori yaitu tajam dan non tajam. Sampah infeksius padat kategori tajam itu seperti jarum (suntik dan jahit), dan botol kaca/vial. Sedangkan sampah infeksius padat kategori

non tajam seperti alat pelindung diri (APD) meliputi masker, *handscoot*, apron, *cover shoes*, *head cap*), botol infus plastik, dan badan suntik. Bagan



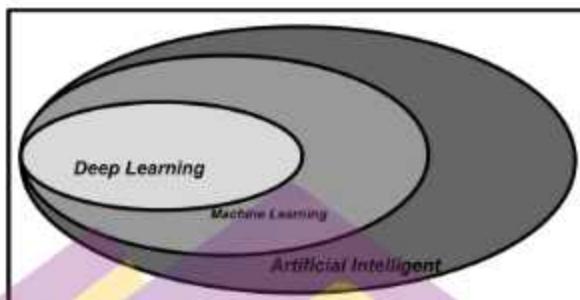
Gambar 1. Bagan jenis sampah

jenis sampah digambarkan pada Gambar 1 berikut.

### 2.3.2 Deep Learning

Deep learning merupakan bagian dari metode *machine learning* yang menggunakan *multi layer "deep" neural network* untuk pembelajaran representasi dari data yang menekankan pada pembelajaran layer (lapisan). Hubungan *deep learning* dengan *machine learning* seperti Gambar 2. Kata “*deep*” pada *deep learning* mengacu pada layer yang berurutan. Banyaknya lapisan yang digunakan pada suatu model disebut kedalaman (*depth*). *Deep learning* sering melibatkan puluhan atau ratusan lapisan yang berurutan. Dan semuanya dipelajari dari data *training*. Berbeda dengan teknik *machine learning* tradisional, *deep learning* melakukan representasi dari data seperti gambar, text, atau video tanpa

memberlakukan aturan kode.

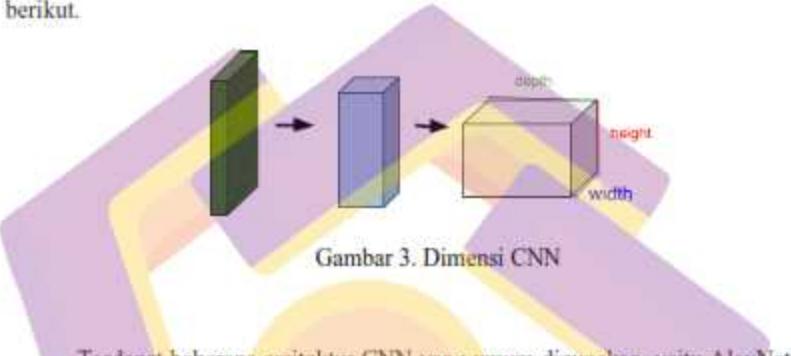


Gambar 2. Hubungan *deep learning* dengan *machine learning*

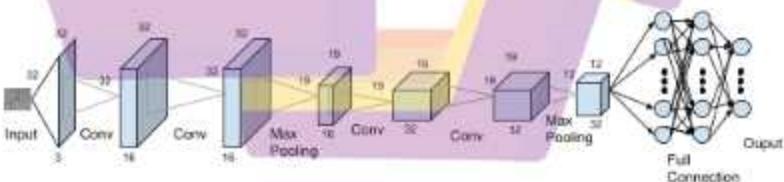
Pada tahun 2012 *deep neural network* mulai terkenal saat memenangkan *Image Recognition Competition* dengan selisih yang cukup signifikan dari juara kedua non *deep learning* (Ha & Tang, 2021). Keberhasilan ini menunjukkan kinerja *deep learning* ketika diakselerasikan dengan perangkat keras yang cepat dan dataset yang besar mampu mencapai hasil yang sangat baik daripada metode konvensional. Para peneliti dan praktisi kemudian memperhitungkan bahwa *deep learning* mampu mengatasi masalah *Computer Vision* (CV), *Natural Language Processing* (NLP), *Reinforcement Learning* (RL), *Computational Biology* dalam beberapa bidang dengan terobosan teknologi dan mencapai hasil mutakhir.

### 2.3.3 Convolutional Neural Network (CNN)

Metode CNN merupakan pengembangan dari model *Multi Layer Perceptron* (MLP) yang didesain untuk mengolah data dua dimensi. Dalam CNN setiap neuron dipresentasikan dalam bentuk tiga dimensi seperti pada Gambar 3 berikut.



Terdapat beberapa arsitektur CNN yang umum digunakan, yaitu AlexNet, LeNet, ZF Net, GoogLeNet, ResNet, dan VGGNet. Contoh arsitektur CNN seperti pada Gambar 4. Arsitektur CNN terbentuk dari 3 (tiga) layer yaitu *convolutional layer* (Conv), *pooling layer* (Max Pooling), dan *fully-connected layer* (Full Connection).

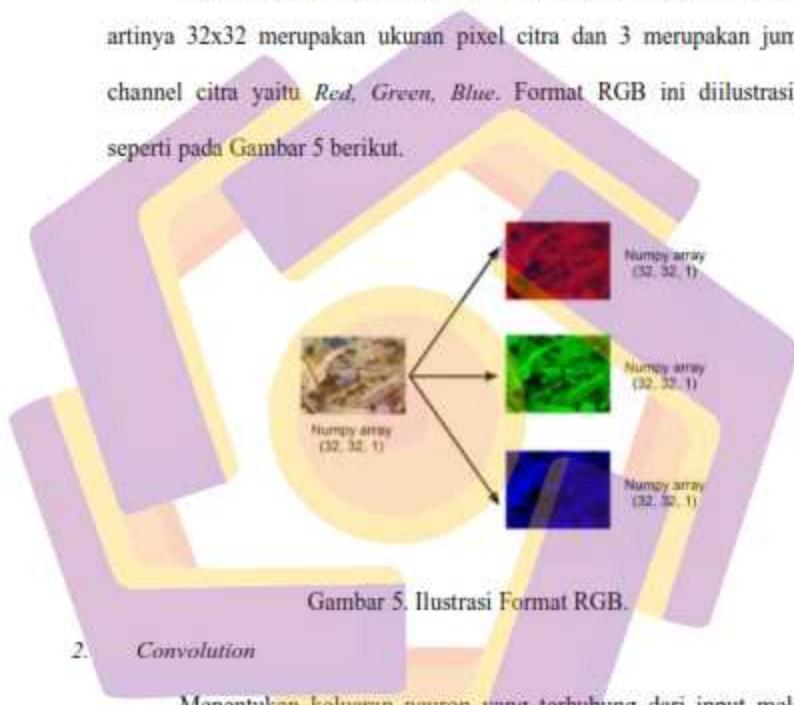


Gambar 4. Arsitektur CNN

Beberapa tahapan dalam membangun model CNN sebagai berikut (O'Shea & Nash, 2015):

### 1. Input

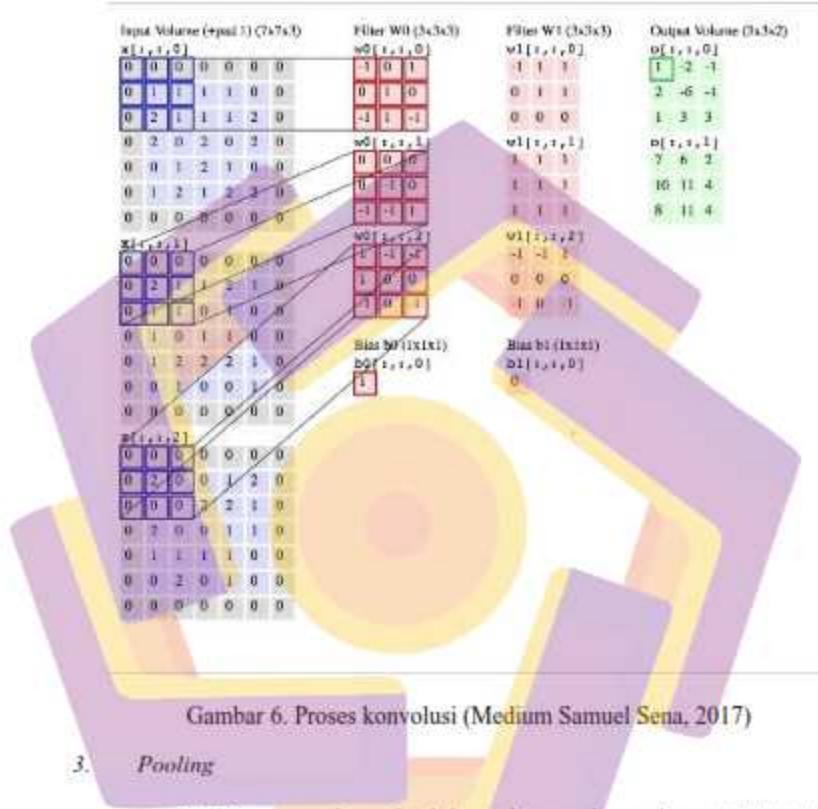
Menyimpan nilai piksel dari citra input. Jika data input  $32 \times 32 \times 3$ , artinya  $32 \times 32$  merupakan ukuran pixel citra dan 3 merupakan jumlah channel citra yaitu *Red*, *Green*, *Blue*. Format RGB ini dilustrasikan seperti pada Gambar 5 berikut.



### 2. Convolution

Menentukan keluaran neuron yang terhubung dari input melalui perhitungan skalar produk antara bobot dan daerah yang terhubung dengan input. *Convolutional* terdiri dari beberapa layer yang tersusun membentuk filter dengan panjang dan tinggi (*pixel*). Ketiga *pixel* akan digeser keseluruhan bagian dari gambar. Setiap pergeseran dilakukan proses dot

antara input dan nilai dari filter sehingga menghasilkan sebuah output yang disebut *feature map*.

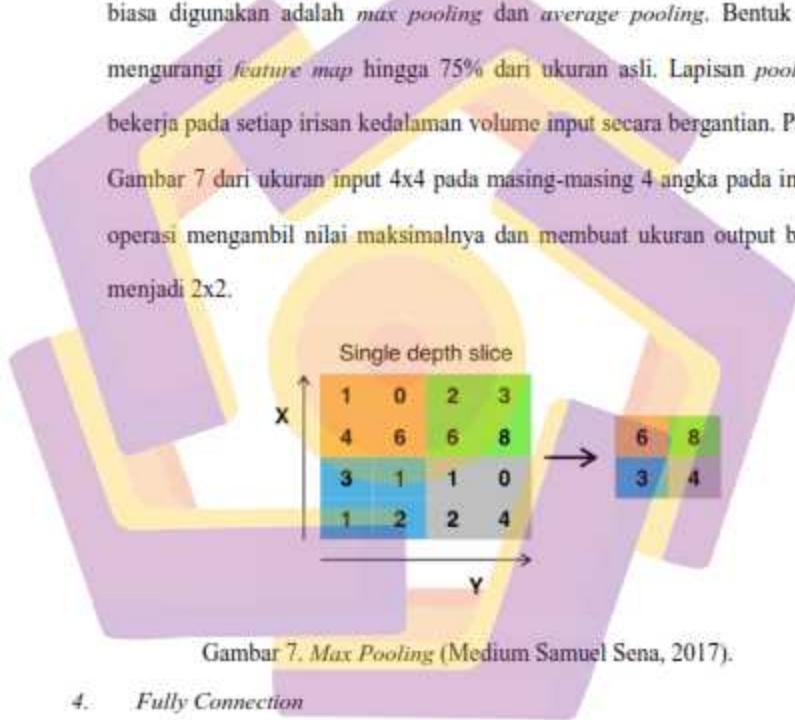


Gambar 6. Proses konvolusi (Medium Samuel Sena, 2017)

### 3. Pooling

Pooling merupakan sebuah layer dengan ukuran dan stride tertentu yang bergeser pada seluruh area *feature map*. Tujuan penggunaan pooling adalah mengurangi dimensi dari *feature map* sehingga mempercepat komputasi dengan parameter yang harus *update* semakin sedikit dan mengatasi *overfitting*. Hal terpenting dalam pemodelan CNN dengan

memilih banyak jenis lapisan pooling sehingga dapat menguntungkan kinerja model (Lee dkk., 2015). Pooling bekerja di setiap tumpukan *feature map* dan mengurangi ukurannya. Bentuk umum lapisan pooling menggunakan ukuran  $2 \times 2$  yang diaplikasikan dengan langkah sebanyak 2 kemudian beroperasi pada setiap irisan dari input. Lapisan *pooling* yang biasa digunakan adalah *max pooling* dan *average pooling*. Bentuk ini mengurangi *feature map* hingga 75% dari ukuran asli. Lapisan *pooling* bekerja pada setiap irisan kedalaman volume input secara bergantian. Pada Gambar 7 dari ukuran input  $4 \times 4$  pada masing-masing 4 angka pada input operasi mengambil nilai maksimalnya dan membuat ukuran output baru menjadi  $2 \times 2$ .



#### 4. Fully Connection

*Feature map* yang dihasilkan masih berbentuk multi dimensi *array* sehingga masih perlu dilakukan *reshape feature map* sehingga berbentuk vektor agar bisa digunakan sebagai *input* lapisan *fully connection*. Lapisan *fully*

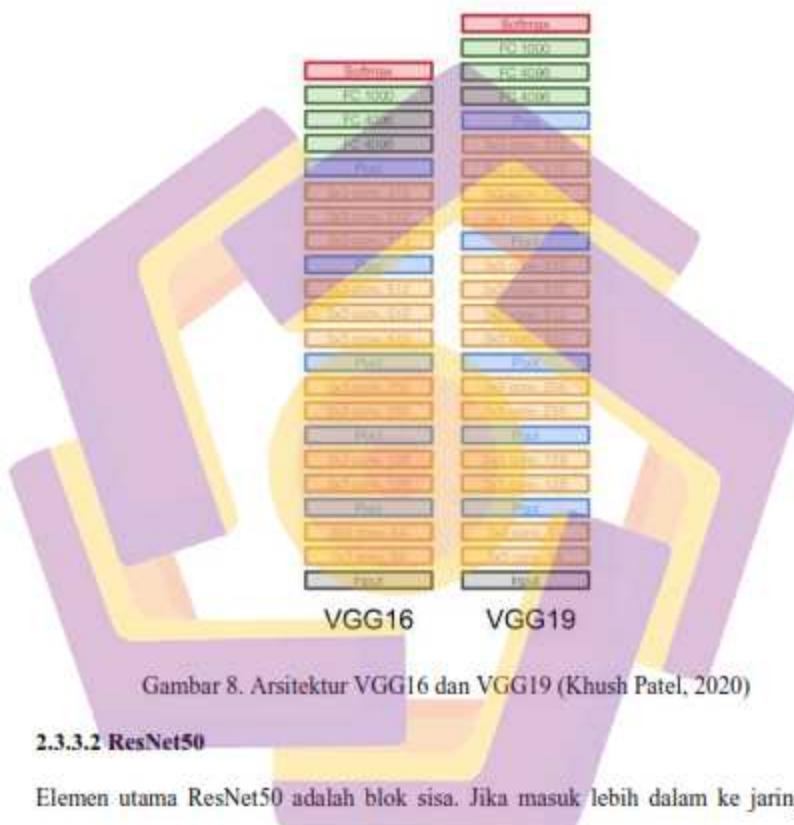
*connection* adalah lapisan dimana semua neuron dari lapisan sebelumnya hingga lapisan setelahnya terhubung semua seperti jaringan syaraf tiruan. Setiap aktivitas neuron dari lapisan sebelumnya diubah menjadi satu dimensi sebelum dihubungkan ke semua neuron di lapisan *fully connection*. Pada lapisan ini digunakan metode multi lapisan perceptron untuk mengolah data sehingga bisa diklasifikasikan.

#### 2.3.3.1 VGG

VGG merupakan *deep learning* yang banyak digunakan dalam banyak teknik klasifikasi gambar dan populer karena kemudahan implementasinya. VGG memiliki banyak keunggulan dan masih merupakan salah satu arsitektur terbaik hingga saat ini. Jaringan VGG dibentuk oleh banyak lapisan konvolusi dengan peningkatan kedalaman dan kernel kecil  $3 \times 3$  di semua lapisan konvolusi. Fokus pada penelitian ini pada dua model VGG :

VGG 16 adalah arsitektur dengan 16 lapisan dengan sepasang lapisan konvolusi, lapisan pooling dan lapisan *fully connected*. Model ini menyimpan filter yang sangat kecil dengan  $3 \times 3$  konvolusi, dan hanya mempertahankan struktur yang sangat sederhana dari  $3 \times 3$  konversi ini dengan penyatuan periodik di seluruh jaringan. VGG memiliki filter yang lebih kecil dengan kedalaman yang lebih dalam daripada filter yang besar seolah-olah hanya memiliki satu lapisan konvolusi  $7 \times 7$ . Arsitektur VGG16 memiliki 16 lapisan konvolusi dan *fully connected*. Dan VGG19 memiliki 19 lapisan konvolusi. Keduanya memiliki

arsitektur yang sangat mirip, tetapi dengan beberapa lapisan konvolusi yang membedakannya.

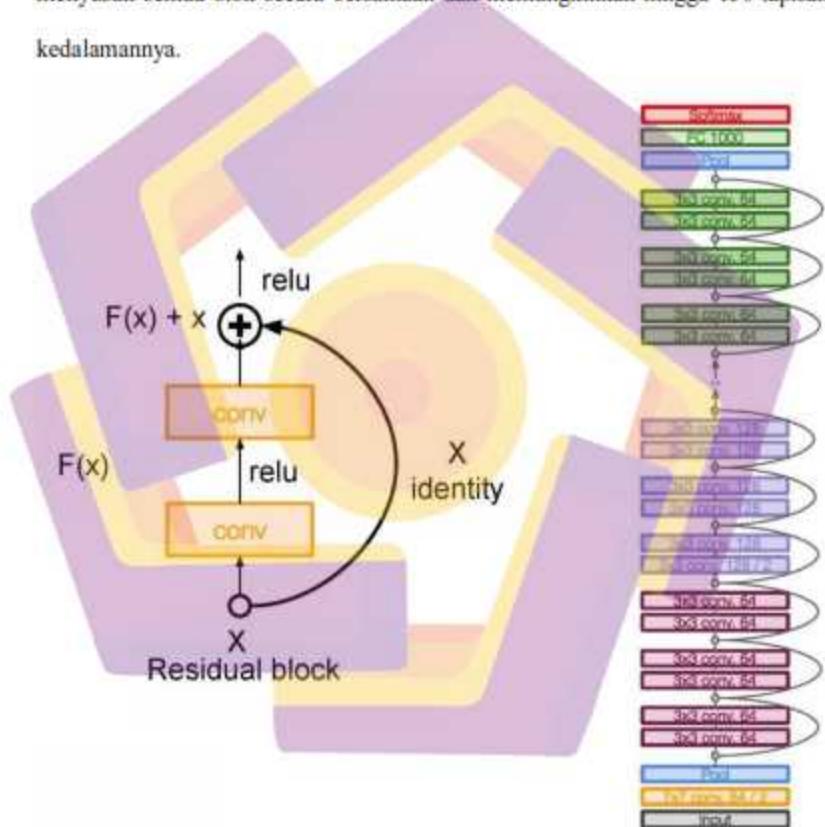


Gambar 8. Arsitektur VGG16 dan VGG19 (Khush Patel, 2020)

### 2.3.3.2 ResNet50

Elemen utama ResNet50 adalah blok sisa. Jika masuk lebih dalam ke jaringan dengan sejumlah besar lapisan, perhitungan menjadi lebih kompleks. Lapisan-lapisan ini diletakkan di atas satu sama lain dan setiap lapisan mencoba mempelajari beberapa pemetaan mendasar dari fungsi yang diinginkan dan

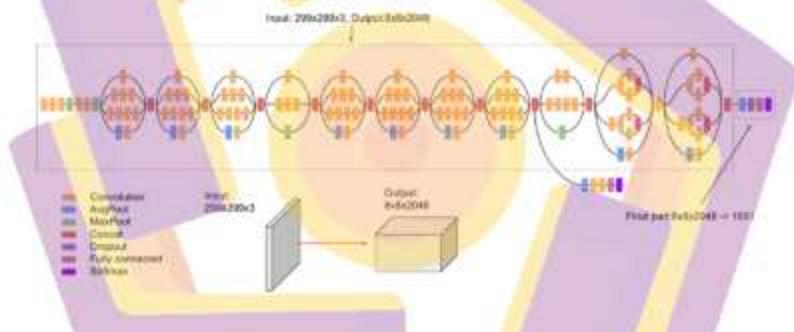
mencoba memiliki blok-blok dan menyesuaikan pemetaan residu. Jika masuk lebih dalam ke jaringan, sangat sulit untuk mempelajari  $H(X)$  karena memiliki banyak lapisan. Koneksi digunakan untuk melewati dan mempelajari input langsung  $F(x)$  dari  $x$  sebagai output akhir. Jadi  $F(x)$  disebut Residual. ResNet50 menyusun semua blok secara bersamaan dan memungkinkan hingga 150 lapisan kedalamannya.



Gambar 9. Arsitektur ResNet50 (Khush Patel, 2020)

### 2.3.3.3 InceptionV3

InceptionV3 adalah model CNN yang digunakan secara luas yang telah terbukti mencapai akurasi lebih dari 78,1% pada dataset ImageNet. Model dikembangkan oleh banyak peneliti selama bertahun-tahun. InceptionV3 terdiri dari blok bangunan simetris dan asimetris, termasuk *average pooling*, *max pooling*, *dropouts*, and lapisan *fully connected*. *Loss* dihitung menggunakan *Softmax*. InceptionV3 bekerja dengan faktorisasi konvolusi dimana mengurangi jumlah koneksi dan parameter untuk dipelajari untuk meningkatkan kecepatan dan memberikan kinerja yang baik.

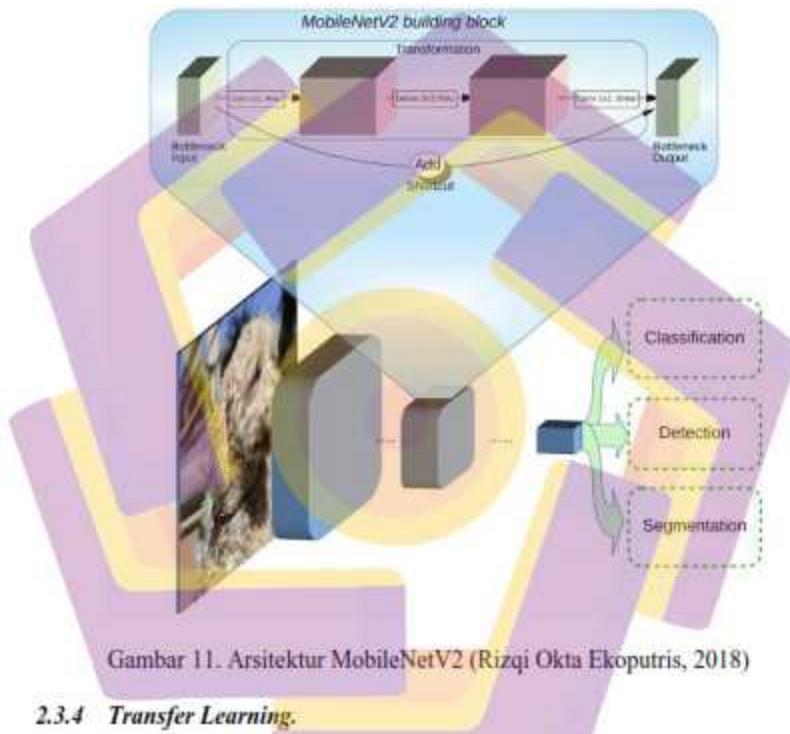


Gambar 10. Arsitektur InceptionV3 (Khush Patel, 2020)

### 2.3.3.4 MobileNetV2

MobileNetV2 menggunakan *depthwise* dan *pointwise convolution* dengan menambahkan dua fitur baru yaitu *linear bottleneck*, dan *shortcut connections* antar *bottlenecks*. Pada bagian *bottleneck* terdapat input dan output antar model sedangkan lapisan bagian dalam melakukan enkapsulasi kemampuan model untuk

mengubah input dari konsep tingkat piksel yang lebih rendah ke kategori gambar tingkat yang lebih tinggi. Pada akhirnya, seperti halnya koneksi residual pada CNN tradisional, shortcut antar bottlenecks memungkinkan *training* yang lebih cepat dan akurasi yang lebih baik



Gambar 11. Arsitektur MobileNetV2 (Rizqi Okta Ekoputris, 2018)

#### 2.3.4 Transfer Learning.

Perubahan besar dari algoritma CNN adalah ketersediaan dataset gambar berlabel yang besar disebut ImageNet (Gao & Mosalam, 2018). Dataset ini berisi sekitar 14 juta gambar berlabel dimulai pada tahun 2009 di Lab. kecerdasan artifisial Universitas Standford. Ketersediaan besar-besaran gambar berlabel di

ImageNet memungkinkan peneliti untuk melatih dan menguji arsitektur yang diusulkan dan dibuat perbandingan. *Transfer learning* menggunakan kembali jaringan yang terlatih (pra-pelatihan) dan parameter yang berat untuk memecahkan masalah yang berbeda. Dengan menggunakan jaringan pra-pelatihan, waktu yang dibutuhkan untuk proses pelatihan akan lebih sedikit (Rawat & Wang, 2017). Jaringan disesuaikan dengan masalah yang baru, jika pra-pelatihan bertujuan mengklasifikasikan 1000 kelas dan masalah yang baru adalah klasifikasi biner maka penggantian lapisan terakhir perlu dilakukan untuk menyesuaikan output dari 1000 menjadi 2 kelas saja. Untuk parameter bobot, alternatif yang bisa dilakukan adalah memperbarui semua bobot pada lapisan jaringan, mempertahankan bobot lama, atau memperbarui secara selektif. Dalam *computer vision*, *transfer learning* sangat populer. Karena memungkinkan sebuah model dapat dikembangkan dengan membutuhkan waktu yang lebih pendek. Proses belajar tidak dimulai dari awal, tetapi dimulai dengan beban pra-pelatihan yang telah dipelajari saat memecahkan masalah sebelumnya.

Beberapa tugas yang dilakukan pada proses *transfer learning*, yaitu:

1. Pilih model yang sudah terlatih dimana sesuai dengan target masalah. Ada sejumlah model pra-pelatihan yang tersedia seperti VGG, InceptionV3, MobileNet dan ResNet5.
2. Mengidentifikasi fitur dari masalah, sesuai dengan ukuran dataset dan kesamaan antara dataset pra-pelatihan dan dataset masalah yang baru. Dengan

mengamati dataset pra-pelatihan dan dataset masalah yang baru maka didapatkan satu dari empat kemungkinan:

- a. Dataset masalah yang baru berukuran besar tetapi berbeda dengan dataset pra-pelatihan.
- b. Dataset masalah yang baru berukuran besar dan sangat mirip dengan dataset pra-pelatihan.
- c. Dataset masalah yang baru berukuran kecil dan berbeda dengan dataset pra-pelatihan.
- d. Dataset masalah yang baru berukuran besar dan sangat mirip dengan dataset pra-pelatihan.

Dalam *deep learning*, 1000 gambar berlabel per kelas disebut dataset berukuran kecil. Kesamaan dataset mengacu pada ketersediaan subset masalah yang sama dengan dataset pra-pelatihan. Jika tugasnya mengenali anjing dan kucing menggunakan jaringan pra-pelatihan yang telah dilatih dengan ImageNet, maka ImageNet yang berisi kelas anjing dan kucing dianggap sangat mirip. Namun, apabila dalam penelitian ini bertujuan mengklasifikasikan sampah medis dan ImageNet tidak mengandung jenis kelas ini maka dataset dianggap berbeda. Oleh karena itu dalam *transfer learning* melibatkan dataset yang kecil dan mirip. Model pra-pelatihan dapat digunakan sebagai program ekstraksi fitur terpisah, di mana input dapat diproses sebelumnya oleh model atau bagian dari model ke output tertentu (misalnya vektor angka) untuk setiap gambar input, yang dapat

kemudian digunakan sebagai input saat melatih model baru.

Sebagai alternatif, model pra-pelatihan atau bagian model yang diinginkan dapat diintegrasikan langsung ke dalam model jaringan saraf baru. Dalam penggunaan ini, bobot pra-pelatihan dapat dibekukan sehingga tidak diperbarui saat model baru dilatih. Sebagai alternatif, bobot dapat diperbarui selama pelatihan model baru, mungkin dengan tingkat pembelajaran yang lebih rendah, memungkinkan model yang telah dilatih sebelumnya bertindak seperti skema inisialisasi bobot saat melatih model baru.

### 2.3.5 Confusion Matrix.

Merupakan metode untuk mengukur performa suatu model klasifikasi dengan mencari nilai *accuracy*, *precision*, *recall*, dan *F1-Score*. Beberapa istilah dasar yang digunakan dalam pencarian nilai *precision*, *recall*, dan akurasi adalah nilai *true positive (TP)*, *true negative (TN)*, *false positive (FP)*, dan *false negative (FN)* sebagaimana ditunjukkan seperti pada tabel 2.8 berikut.

Tabel 2.8 *Confusion Matrix*

		Kelas Prediksi	
Kelas Sebenarnya		Positif	Negatif
		Positif	TP
	Negatif	FP	TN

Nilai *true positive* didefinisikan sebagai *positive tuple* yang diklasifikasikan dengan benar oleh model. *True negative* sebagai *negative tuple* yang diklasifikasikan dengan benar oleh model. Sementara *false positive* adalah *negative tuple* yang diklasifikasikan sebagai kelas positif oleh model. Dan *false negative* adalah *positive tuple* yang diklasifikasikan sebagai kelas negatif oleh model. Berdasarkan *confusion matrix*, maka kinerja model klasifikasi dapat dihitung (Sarang Narkhede, 2018).

1. Akurasi (*accuracy*) menggambarkan seberapa akurat model dalam melakukan klasifikasi dengan benar.

$$\text{Accuracy} = (\text{TP} + \text{TN}) / (\text{TP} + \text{FP} + \text{FN} + \text{TN})$$

2. Presisi (*precision*) menggambarkan akurasi antara data yang diminta dengan hasil prediksi yang diberikan oleh model.

$$\text{Precision} = \text{TP} / (\text{TP} + \text{FP})$$

3. *Recall* menggambarkan keberhasilan model dalam menemukan kembali sebuah informasi.

$$\text{Recall} = \text{TP} / (\text{TP} + \text{FN})$$

4. *F1-score* menggambarkan perbandingan rata-rata *precision* dan *recall* yang dibobotkan. *Accuracy* tepat kita gunakan sebagai acuan performansi algoritma jika dataset kita memiliki jumlah data False Negatif dan False

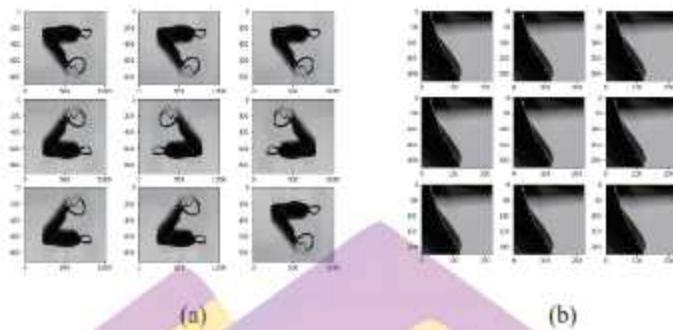
Positif yang sangat mendekati (*symmetric*). Namun jika jumlahnya tidak mendekati, maka sebaiknya kita menggunakan *F1-score* sebagai acuan.

$$F1\text{-score} = (2 * \text{Recall} * \text{Precision}) / (\text{Recall} + \text{Precision})$$

### 2.3.6 Augmentasi Data

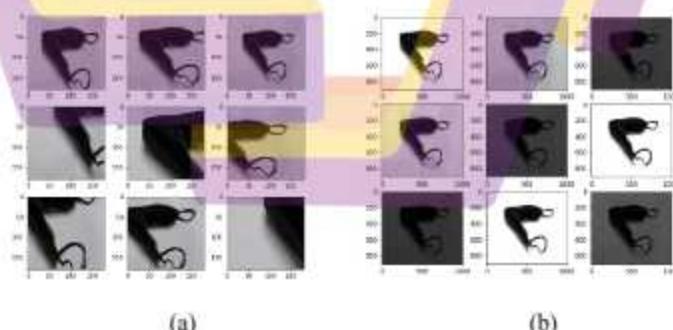
Augmentasi data merupakan suatu proses memanipulasi atau memodifikasi sebuah objek gambar, sehingga gambar asli menjadi bentuk standar yang akan diubah bentuk dan posisinya (Adhi Setiawan, 2021). Augmentasi data dilakukan agar mesin dapat belajar dan mengenali objek dalam berbagai macam gambar sekaligus untuk memperbanyak data. Beberapa penelitian, penggunaan augmentasi data berhasil meningkatkan performa model. Hal ini dikarenakan mesin dapat mengenali banyak bentuk dan pola dari sebuah objek. Pada *deep learning*, augmentasi data dapat membantu mengatasi masalah umum pada *deep learning* yaitu data *hungry* (membutuhkan jumlah data yang banyak). Proses augmentasi data membuat setiap data akan mendapatkan data baru. Data baru tersebut bisa didapatkan lebih banyak lagi dengan mengkombinasikan beberapa jenis augmentasi data.

1. *Flip*. Jenis augmentasi data dimana membalik posisi suatu gambar secara vertikal maupun horisontal. Tidak semua gambar boleh dilakukan *flip*, seperti gedung jika dilakukan *flip* maka akan menjadi tidak masuk akal. Gambar 12a merupakan hasil augmentasi data flip sebagai berikut.



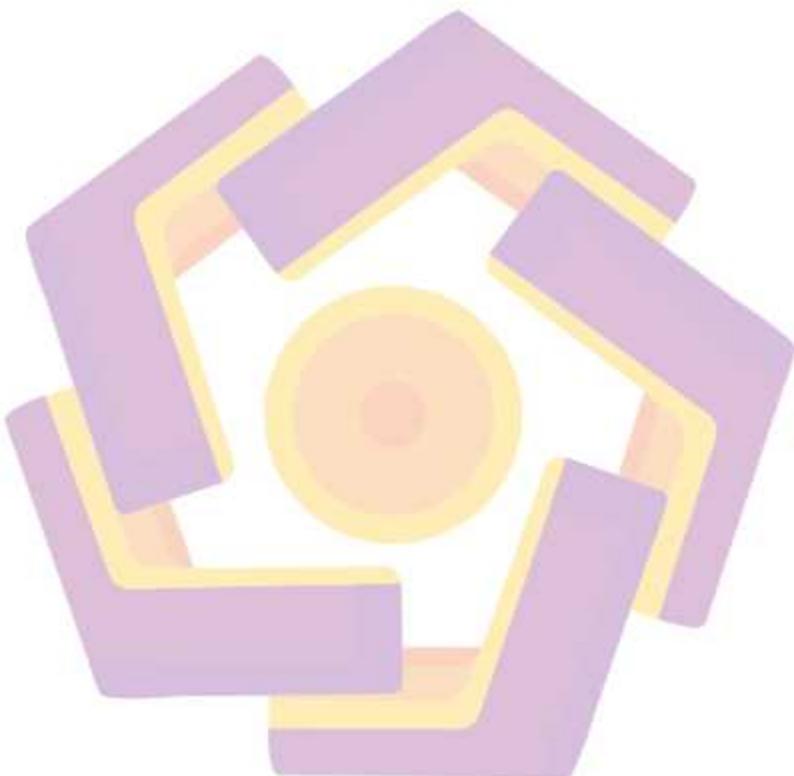
Gambar 12. Augmentasi data (a) *random flip* (b) *random crop*.

2. *Random crop*. Augmentasi data dimana melakukan pemotongan sebuah gambar. Pemotongan dilakukan secara *random*, dengan memberikan parameter *size* yang harus ditentukan untuk melakukan pemotongan. Gambar 8b di atas merupakan contoh augmentasi *random crop*.
3. Random resize. Augmentasi data dimana melakukan perubahan ukuran (*resize*) gambar. Parameter yang digunakan sama dengan *crop*, dimana nilai *size* ditentukan sendiri seperti pada Gambar 13a berikut.



Gambar 13. Augmentasi data (a) *random resize* (b) *brightness*.

4. *Brightness.* Augmentasi data dimana melakukan perubahan tingkat kecerahan suatu gambar. *Brightness* dilakukan beragam, tergantung nilai derajat yang ditentukan. Hasil augmentasi brightness seperti pada Gambar 13b di atas.



## BAB III

### METODE PENELITIAN

#### 3.1. Jenis, Sifat, dan Pendekatan Penelitian

Jenis penelitian ini adalah penelitian eksperimen yang akan melakukan dengan beberapa skenario untuk menguji dan membandingkan arsitektur CNN dalam melakukan klasifikasi sampah medis. Pendekatan penelitian menggunakan pendekatan kuantitatif dengan parameter keberhasilan yang diukur adalah akurasi (*accuracy*), *precision*, *recall*, dan *F1-score*.

#### 3.2. Metode Pengumpulan Data

Pengumpulan data dilakukan sendiri dengan memotret sampah medis yang dihasilkan oleh pelayanan kesehatan masyarakat. Total gambar yang dihasilkan 368 gambar dengan format .tiff dengan rincian seperti pada tabel 3.1 di bawah ini.

Tabel 3.1 Dataset sampah medis.

Jenis Sampah	Jumlah	Total kelas	Kelas
APD	65		non tajam
Glove	57	249	non tajam
Headcap	52		non tajam
Masker	75		non tajam
Suntik	59	119	tajam
botol vial	60		tajam

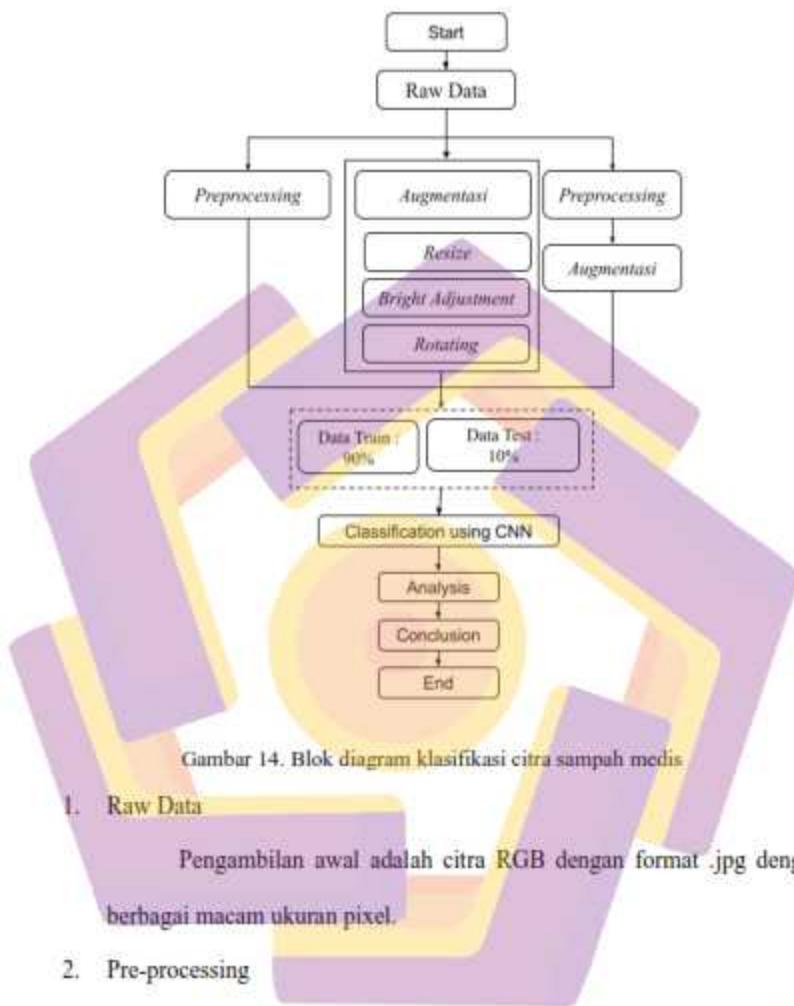
### 3.3. Metode Analisis Data

Penelitian ini membandingkan arsitektur CNN untuk dilakukan pelatihan menggunakan *transfer learning*. Untuk menentukan keakuratan klasifikasi pada berbagai gambar, data input dibagi menjadi data *training* dan *testing*. Fase penelitian terdiri dari pelatihan struktur jaringan CNN yang disiapkan dan menentukan akurasi klasifikasi pada data input, membagi dataset menjadi data *training* dan data *test*. Empat pembagian yang digunakan: 90% (data *training*) - 10% (data *test*), 80% (data *training*) - 20% (data *test*), 70% (data *training*) - 30% (data *test*) dan 60% (data *training*) - 40% (data *test*). Terbentuknya pola dimana jika rasio data training semakin besar maka data *misclassified* akan semakin menurun, begitu juga sebaliknya (Bobulski & Kubanek, 2019).

Pada penelitian ini alasan utama menggunakan pembagian 90% data *training* dan 10% data *testing* adalah terbatasnya dataset yang digunakan. Dengan dataset yang terbatas tidak memungkinkan mengambil data *testing* terlalu besar (Meng & Chu, 2020). Sehingga proses selanjutnya dilakukan uji validasi model dengan membagi data 90% data *training* dan 10% data *test* untuk tahap selanjutnya adalah klasifikasi menggunakan metode CNN dan menguji hasil klasifikasi menggunakan *confusions matrix*. Ukuran keberhasilan dalam penelitian ini adalah menggunakan akurasi (*accuracy*), *precision*, *recall*, dan *F1-score*.

### 3.4. Alur Penelitian

Pada alur penelitian klasifikasi sampah medis ditunjukkan seperti pada Gambar 14 proses utama penelitian ini sebagai berikut:



Gambar 14. Blok diagram klasifikasi citra sampah medis

#### 1. Raw Data

Pengambilan awal adalah citra RGB dengan format jpg dengan berbagai macam ukuran pixel.

#### 2. Pre-processing

Proses ini terdiri dari 2 (dua) tahap yaitu proses *resizing* dan *rotating* data gambar serta anotasi data. Proses *resizing* dan *rotating* dilakukan untuk keperluan data input, citra disamakan ukurannya. Sedangkan untuk kebutuhan pengujian proses pre-processing perlu pemberian gangguan pada citra, yaitu *blurring* atau *bright adjustment*.

Proses anotasi data yaitu proses memberi keterangan pada citra berupa informasi.

### 3. Pelatihan dan Model Pelatihan

Melakukan proses pelatihan dengan menggunakan dataset citra pelatihan pada penelitian ini. Mendapatkan bobot awal dan model CNN sehingga dihasilkan bobot hasil pelatihan yang nantinya akan digunakan pada proses pengujian.

### 4. Pengujian dan Model Pengujian

Proses pengujian terhadap citra pengujian dengan menggunakan bobot hasil pelatihan. Menggunakan citra yang normal dan citra noise seperti blurring, bright adjustment.

### 5. Confusion Matrix.

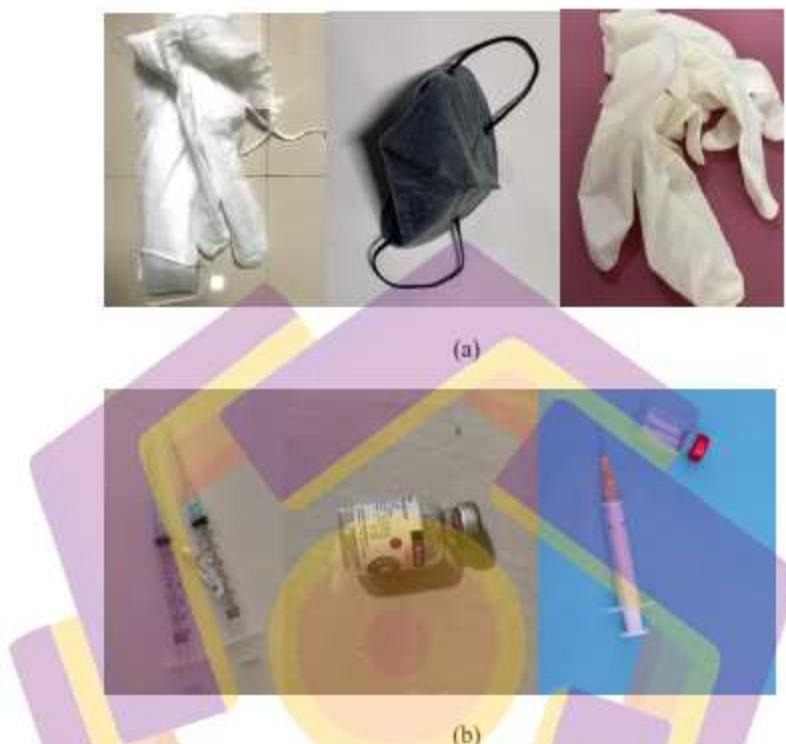
Menghitung hasil kinerja algoritma klasifikasi dengan mencari nilai matriks evaluasi seperti akurasi (*accuracy*), *precision*, *recall*, dan *F1-score*.

## **BAB IV**

### **HASIL PENELITIAN DAN PEMBAHASAN**

#### **4.1. Pengumpulan Data (*Raw Data*).**

Klasifikasi sampah ini menggunakan gambar dari kumpulan data yang didedikasikan untuk klasifikasi sampah medis yang telah diambil langsung menggunakan kamern dari pengelolaan sampah medis yang terdapat pada pelayanan kesehatan masyarakat. Dataset ini memiliki total 368 gambar di mana satu objek sampah medis dengan latar belakang yang bersih. Konfigurasi pencahayaan dan pose untuk setiap objek berbeda. Untuk melatih *deep neural network*, membutuhkan banyak gambar *training*. Dengan membalik dan memutar, kami menambah kumpulan data menjadi 1104 gambar. Sejumlah faktor penting harus diperhitungkan saat mengambil gambar yang tepat. Pertama-tama, ukuran input gambar merupakan elemen penting. Resolusi yang terlalu tinggi mengakibatkan peningkatan jumlah perhitungan, sehingga menyebabkan kelebihan memori perangkat komputasi yang digunakan. Di sisi lain, resolusi input terlalu rendah data bisa saja menghalangi pencapaian kinerja yang diharapkan. Pada penelitian ini memutuskan menggunakan ukuran  $128 \times 128$  piksel terlebih dahulu. Asumsi bahwa resolusi gambar masukan adalah  $128 \times 128$  adalah asumsi eksperimental. Pilihan ini memungkinkan *testing* untuk gambar hampir dua kali lebih kecil pada penelitian yang sudah dilakukan (Bobulski & Kubanek, 2019). Beberapa contoh gambar dalam dataset ini ditunjukkan pada Gambar 15.



Gambar 15. Sampah infeksius (a) non tajam (b) tajam

*Preprocessing* input untuk data *training* dan *testing* adalah proses penting dalam menyelesaikan permasalahan klasifikasi sampah medis yang benar dalam kondisi sampah medis yang alami. Dalam penelitian *deep learning*, sebanyak mungkin data harus dikumpulkan untuk setiap kelas yang diidentifikasi. Pada penelitian ini, perlu untuk mengumpulkan dataset sampah terkласifikasi. Penelitian ini mengadopsi model yang disederhanakan di mana hanya ada satu sampah medis di dalam lensa kamera. Pendekatan ini tidak mencerminkan kondisi sampah medis yang alami, tetapi untuk kebutuhan penelitian memberikan peluang yang cukup untuk menghasilkan kerja CNN yang berfungsi dengan baik. Selain itu tujuan

penelitian ini adalah menyediakan sistem pemilah (robotic) sampah medis dimana sampah yang digunakan memiliki kondisi latar belakang yang terkontrol. Sehingga dataset yang disajikan adalah dataset terkontrol. Semua gambar yang dikumpulkan mewakili objek yang diklasifikasikan. Jumlah kelas yang dipertimbangkan dalam klasifikasi sampah medis menjadi dua kelas yaitu sampah infeksius tajam dan sampah infeksius non-tajam. Pembagian ini berdasarkan pengelolaan sampah medis yang memiliki kesamaan. Karena ketersediaan sampah masing-masing kelas pada fasilitas penelitian berbeda, maka mengakibatkan jumlah gambar yang berbeda pada masing-masing kelas yang telah dikumpulkan. Untuk menambah jumlah gambar pada masing-masing kelas, perlu membuat salinan gambar yang diputar dengan sudut rotasi yang berbeda dalam setiap kelas. Kumpulan data ini menjadi cukup untuk dilakukan proses *training* dan *testing* dari struktur jaringan yang disiapkan.

#### **4.2. Preprocessing.**

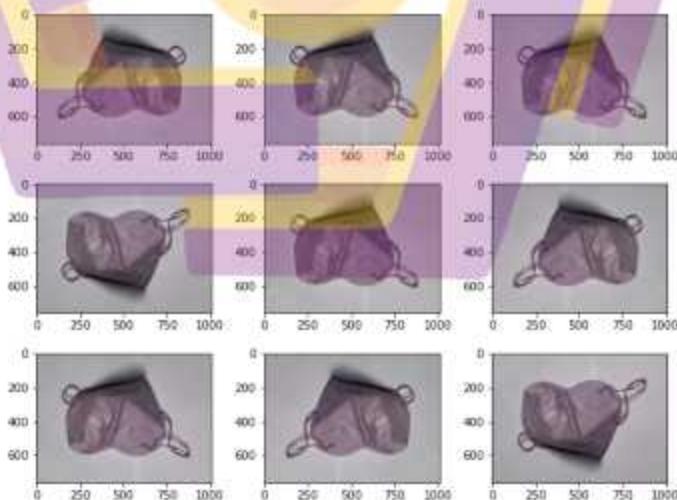
*Preprocessing* diperlukan untuk mendapatkan kualitas citra yang baik sebelum ekstraksi, dan klasifikasi, yang diperlukan untuk meningkatkan kualitas citra, akan meningkatkan kinerja klasifikasi (Syeda Farha Shazmeen, 2013). Tahap *preprocessing* dalam proses preparasi adalah:

1. Pengubahan Ukuran: Perubahan ukuran (*resize*) dilakukan pada gambar diubah dengan menggunakan parameter yang sama. Nilai size menjadi 224x224 piksel untuk proses ekstraksi. Perubahan ukuran disini tanpa dilakukan pemotongan (*crop*).

2. Augmentasi: Augmentasi gambar adalah proses mengubah beberapa gambar untuk memberikan variasi pada gambar yang sama. Hal ini dapat membantu algoritma dalam melakukan klasifikasi dan mengurangi kemungkinan overfitting. Augmentasi gambar yang digunakan meliputi *zoom*, *brightness*, *rotation*, *vertikal flip*, dan *horizontal flip*. Gambar 16 merupakan gambar asli, sedangkan Gambar 17 adalah gambar setelah dilakukan augmentasi.



Gambar 16. Gambar sebelum augmentasi.



Gambar 17. Gambar setelah augmentasi.

#### 4.3. Klasifikasi Model CNN.

Percobaan awal adalah membandingkan hasil akurasi (*accuracy*, *precision*, *recall*, dan *F1-score*) tanpa proses *preprocessing* dan augmentasi data. Pada proses *preprocessing*, rasio perbandingan data train, data validasi, data test adalah 70:15:15. Pembagian dataset ini harus dilakukan di awal tahap. Komposisi pembagian bisa berbeda-beda. Pada umumnya dibagi menjadi 3 subset yaitu data *training*, data *validasi*, dan data *test*. Agar tidak merusak proses *training* model, ukuran *training* jauh lebih besar dari data *validasi*. Karena jika data *training* terlalu kecil maka model tidak akan belajar (Bobulski & Kubanek, 2019). Tabel 4.1 di bawah ini menunjukkan bahwa proses *preprocessing* berhasil meningkatkan *accuracy* dari data asli. Percobaan selanjutnya setelah menerapkan proses *preprocessing* adalah augmentasi data. Tidak semua jenis augmentasi data dapat meningkatkan *accuracy*. Teknik augmentasi yang tepat disesuaikan dengan karakter data. Augmentasi data yang digunakan *horizontal flip*, *brightness* dengan melipatgandakan jumlah data asli. Sehingga didapatkan hasil seperti pada Tabel 4.2 di bawah ini. Percobaan awal adalah membandingkan hasil akurasi (*accuracy*, *precision*, *recall*, dan *F1-score*) tanpa proses *preprocessing* dan augmentasi data seperti pada tabel berikut.

Tabel 4.1 Perbandingan *accuracy* dengan *preprocessing*.

<b>epoch</b>	<b><i>accuracy (%)</i> 368 gambar</b>	<b><i>accuracy (%)</i> 736 gambar</b>
50	48.21%	92.79%

Tabel 4.2 Perbandingan augmentasi data

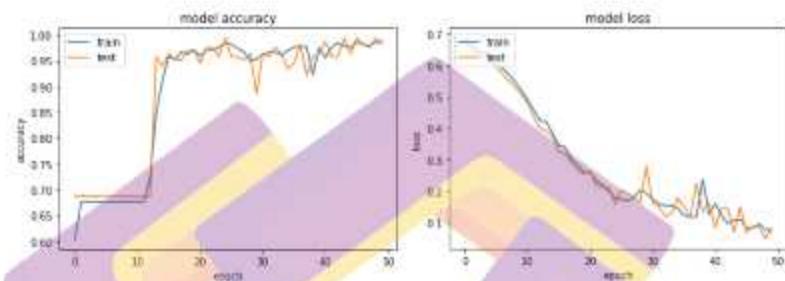
Augmentasi data	Accuracy (%) 2x data (736 gambar)	Accuracy (%) 3x data (1104 gambar)
rescale=1./255		
channel_shift_range=100	92.79%	99.40%
horizontal flip		
brightness range=[0.2,1.2]		

Dari kedua tabel di atas membuktikan bahwa pada penelitian ini teknik augmentasi data dan preprocessing dapat meningkatkan akurasi (*accuracy*, *precision*, *recall*, dan *F1-score*) dari model yang dibangun. Untuk menyelidiki kinerja CNN dasar, pada penelitian ini dibangun arsitektur CNN sederhana untuk mendapatkan hasil secara umum untuk membantu mengetahui perbedaan kinerja antara model CNN. Arsitektur ini menggunakan lapisan konvolusi 2D untuk menangkap fitur gambar. Dengan menggunakan filter  $3 \times 3$  memungkinkan lebih banyak fungsi aktivasi nonlinier dan mengurangi jumlah parameter daripada menggunakan filter yang lebih besar (Meng & Chu, 2020). Adapun penjelasan lebih rinci masing-masing model CNN sebagai berikut:

#### 4.3.1 VGG16

Grafik *accuracy* pelatihan/pengujian dan loss pelatihan/pengujian seiring dengan meningkatnya jumlah *epoch*. Model sederhana tersebut mencapai akurasi data pelatihan 91,72% dan data validasi 89,73% menggunakan pemisahan data pelatihan/validasi 90/10 dengan menghasilkan data gambar yang telah kita buat sebelumnya. Tanpa *preprocessing* ini menghasilkan akurasi pelatihan sebesar

41,07%, sehingga menghasilkan data gambar memiliki efek yang jelas pada kinerja, yang mengarah pada peningkatan akurasi. Grafik *accuracy* dan *loss* ditunjukkan pada Gambar 18.



Gambar 18. Grafik *accuracy* dan *loss* VGG16.

Eksperimen dengan VGG16 cenderung memiliki masalah *overfitting*, seperti kurva validasi yang sangat berfluktuasi dan tidak memiliki tanda-tanda konvergensi jika dibandingkan dengan model lain. Penghitungan *confusion matrix* pada Gambar 19 menunjukkan bahwa arsitektur VGG16 tidak berhasil memprediksi kelas non tajam sejumlah 6.

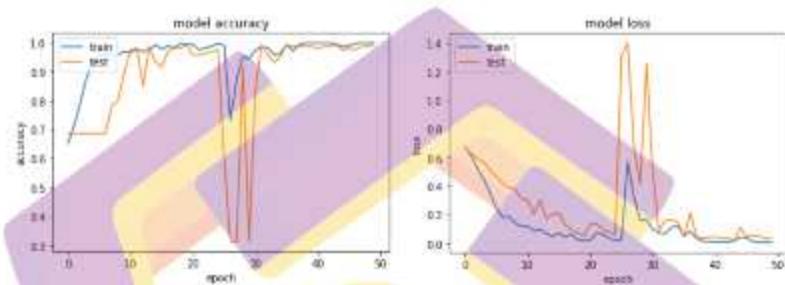


Gambar 19. *Confusion matrix* VGG16.

#### 4.3.2 VGG19

Model VGG19 mencapai akurasi data pelatihan 98,80% dan data validasi 96,1% menggunakan pemisahan data pelatihan/validasi 90/10 menggunakan

dataset yang disediakan. Tanpa *preprocessing*, maka *overfitting* cukup besar, meskipun akurasinya baik. *Preprocessing* penambahan jumlah dataset dapat mengurangi *overfitting* dengan sangat baik. Grafik akurasi dapat dilihat pada Gambar 20.



Gambar 20. Grafik *accuracy* dan *loss* VGG19.

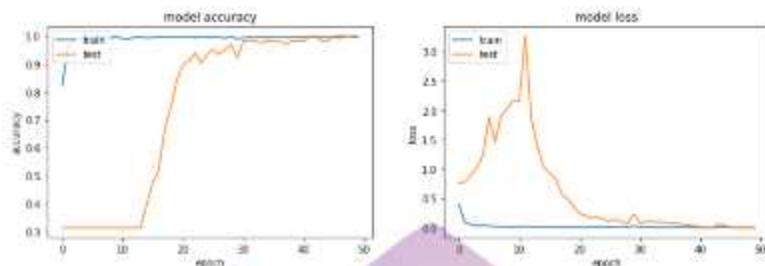
Perhitungan *confusion matrix* VGG19 menurut Gambar 21 bekerja lebih baik daripada VGG16 dengan kesalahan validasi kelas non tajam sebesar 2.



Gambar 21. *Confusion matrix* VGG19.

#### 4.3.3 ResNet50

Kinerja klasifikasi model ResNet50 mencapai akurasi 98,68% dan akurasi validasi 99,40% Gambar 22 menunjukkan evolusi *accuracy* pelatihan/pengujian dan *loss* pelatihan/pengujian seiring dengan meningkatnya jumlah *epoch*.



Gambar 22. Grafik *accuracy* dan *loss* ResNet50.

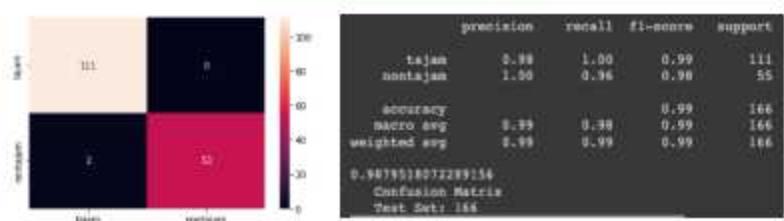
Perhitungan *confusion matrix* pada Gambar 23 menunjukkan penghitungan validasi kelas non-tajam mendekati sempurna.



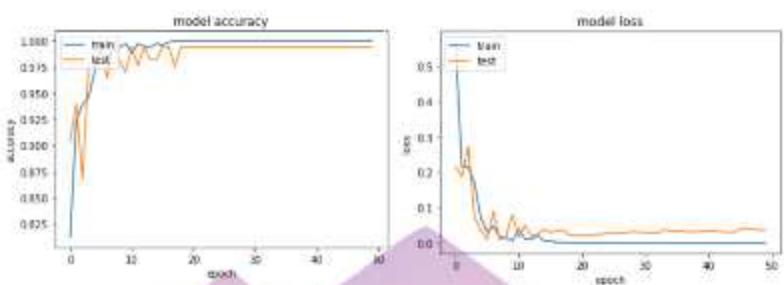
Gambar 23. *Confusion matrix* ResNet50.

#### 4.3.4 InceptionV3

Gambar 24 menunjukkan kinerja klasifikasi model InceptionV3. Model InceptionV3 mencapai akurasi 98,80% dan akurasi pengujian 95,77% dengan *preprocessing*, sedangkan akurasi pengujian baru mencapai 88,63% dan *overfitting clear* tanpa *preprocessing*.



Gambar 24. *Confusion matrix* InceptionV3.

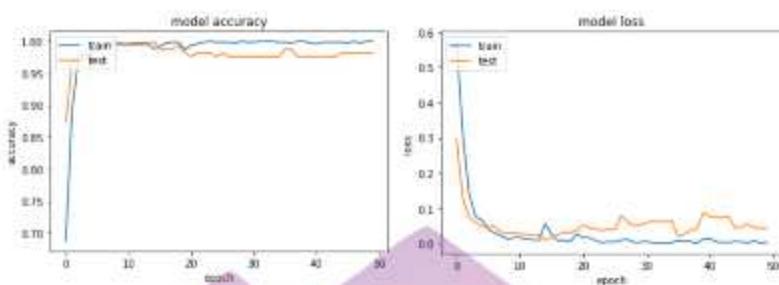


Gambar 25. Grafik *accuracy* dan *loss* InceptionV3.

Grafik *accuracy* pelatihan/pengujian dan *loss* pelatihan/pengujian seiring dengan meningkatnya jumlah epoch. Bahwa *accuracy* dan *loss* lebih menyatu dan efisien dengan *preprocessing*. Lebih lanjut, eksperimen tanpa *preprocessing* cenderung memiliki masalah *overfitting*, seperti kurva validasi yang sangat berfluktuasi dan tidak memiliki tanda-tanda konvergensi.

#### 4.3.5 MobileNetV2

Kinerja klasifikasi model MobileNetV2 mencapai akurasi pelatihan 98,80% dan akurasi pengujian 93,8% dengan *preprocessing*, sedangkan akurasi pengujian baru mencapai 58,93% dan *overfitting clear* tanpa *preprocessing*. Gambar 26 menunjukkan peningkatan *accuracy* dengan mengimplementasikan MobileNetV2 dengan *preprocessing*. Lebih lanjut, eksperimen MobileNetV2 tanpa *preprocessing* cenderung memiliki masalah *overfitting*, seperti tidak adanya tanda-tanda konvergensi.



Gambar 26. Grafik *accuracy* dan *loss* MobileNetV2.

Gambar 27 menunjukkan perhitungan *confusion matrix* MobileNetV2 di mana kesalahan validasi kelas non tajam adalah 2.



Gambar 27. *Confusion matrix* MobileNetV2.

Untuk memahami kinerja masing-masing model dalam mengklasifikasikan dataset sampah medis, makapenghitungan *Confusion matrix* berupa nilai *accuracy*, *precision*, *recall*, dan *F1-score* untuk model VGG 16, VGG19, ResNet50, InceptionV3 dan MobileNetV2 ditampilkan dalam 1. (satu) tabel 4.3 sebagai berikut.

Tabel 4.3 Perbandingan *Confusion Matrix*

	<b>VGG 16</b>	<b>VGG 19</b>	<b>ResNet50</b>	<b>InceptionV3</b>	<b>MobileNetV2</b>
<b>Accuracy</b>	0.97	0.98	0.99	0.98	0.98
<b>Precision</b>					
Tajam	0.95	0.98	0.99	0.98	0.98
Non Tajam	1.00	1.00	1.00	1.00	1.00
<b>Recall</b>					
Tajam	1.00	1.00	1.00	1.00	1.00
Non Tajam	0.99	0.96	0.98	0.96	0.96
<b>F1-Score</b>					
Tajam	0.97	0.99	1.00	0.99	0.99
Non Tajam	0.94	0.98	0.99	0.98	0.98

Dapat dilihat dari tabel 4.4 tersebut bahwa semua model *deep learning* berkinerja baik saat mengklasifikasikan sampah medis baik kelas tajam. Kelas tajam lebih difokuskan karena pengelolaanya lebih beresiko dan berbahaya dibanding kelas non tajam. Hanya untuk VGG16 mampu memprediksi 49 kelas non tajam dengan benar. Dan ResNet50 bekerja dengan baik mampu memprediksi 54 kelas non tajam dengan benar. Hasil ini menunjukkan bahwa dataset sampah medis yang ada cukup seimbang dalam *training* sehingga mampu memberikan akurasi yang baik.

Tabel 4.4 Kinerja Model *Deep Learning*

<b>Model</b>	<b>Misclassified</b>	
	<b>Tajam</b>	<b>Non Tajam</b>
VGG16	6	0
VGG19	2	0
ResNet50	1	0
InceptionV3	2	0
MobileNetV2	2	0

Tabel 4.5 Hasil Pelatihan

Model	Accuracy	Parameters	Training Speed
VGG16	96.39%	138,485,930	1263.88 detik
VGG19	98.80%	143,816,138	1697.11 detik
ResNet50	99.40%	25,687,938	938.80 detik
InceptionV3	98.80%	134,268,738	1287.50 detik
MobileNetV2	98.80%	24,426,786	353.03 detik

Hasil *training* untuk 5 arsitektur CNN yang dilakukan sebanyak 50 epoch, dapat diketahui bahwa model ResNet50 mencapai akurasi tertinggi yang dibutuhkan parameter dan kecepatan pelatihan lebih cepat.

Tabel 4.6 Hasil Pengujian

Model	Accuracy	Training Speed
VGG16	96.39%	1274.62 detik
VGG19	98.80%	1704.52 detik
ResNet50	99.40%	957.16 detik
InceptionV3	98.80%	1296.45 detik
MobileNetV2	98.80%	353.56 detik

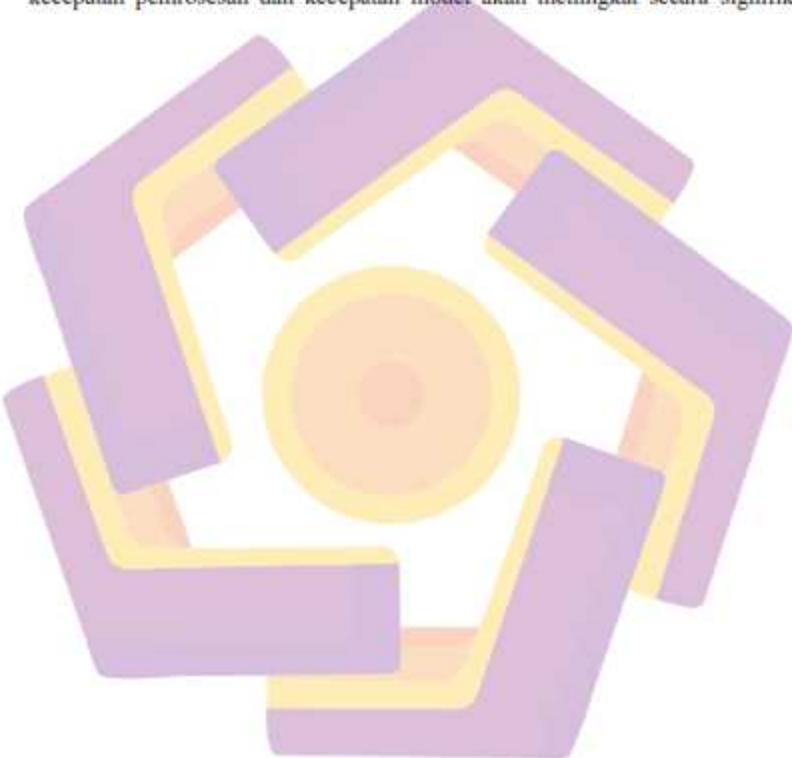
Dataset yang kecil dapat mengurangi waktu dan biaya tenaga kerja yang diperlukan dalam proses anotasi gambar. Sementara itu, *transfer learning* dapat mengurangi waktu yang dibutuhkan model untuk melakukan pelatihan, dan mendapatkan akurasi yang dapat diandalkan. Klasifikasi sampah medis menggunakan *transfer learning* yang diusulkan dalam ini dapat mengurangi risiko tertular penyakit dari klasifikasi sampah konvensional secara manual. Cara ini selain tidak menimbulkan gangguan terhadap kesehatan manusia juga dapat

menghemat banyak sumber daya manusia. Pada akhirnya, kinerja CNN dengan *transfer learning* bekerja baik dengan menghasilkan akurasi yang baik sebesar 99,40%. Percobaan untuk mengklasifikasikan dataset sampah medis yang dibangun ke dalam 2 (dua) kelas telah dilakukan dengan menggunakan metode transfer learning. Tiga model yang digunakan, model VGG19, InceptionV3 dan MobileNetV2 mendapatkan hasil yang sama yaitu 98.80%. Hasil penelitian ini menunjukkan bahwa model ResNet50 mampu mencapai akurasi tertinggi dibandingkan dengan empat model lainnya. Akurasi untuk model ResNet50 adalah 99,40% dengan rata-rata presisi dan recall 100% dan 99%. Penemuan dari penelitian ini berdasarkan perbandingan 5 model deep learning adalah :

1. Memberikan kontribusi dataset baru untuk klasifikasi sampah medis berdasarkan kelas tajam dan non-tajam
2. Penelitian ini mampu mengidentifikasi fokus sampah yang lebih berbahaya, yaitu sampah medis kelas tajam. Hal ini penting karena sampah kelas tajam memiliki pengelolaan yang lebih ekstra dan berbahaya.
3. Penelitian ini menghasilkan nilai *precision* 100% untuk semua model pada kelas non tajam dan nilai *recall* 100% untuk semua model pada kelas tajam.

*Transfer learning* membutuhkan pembelajaran tugas baru dengan parameter model pra-pelatihan. Oleh karena itu, struktur model sebagian besar tidak untuk mengubah struktur jaringan, seperti dengan menambahkan atau menghapus *convolutional layer* atau *pooling layer*. Jika mengubah *convolutional layer* atau *pooling layer*, metode *transfer learning* tidak akan berfungsi. Pada saat yang

sama, spesifikasi perangkat yang berbeda juga akan mempengaruhi kecepatan pelatihan model dan kecepatan pemrosesan satu gambar. Perangkat pada penelitian ini menggunakan perangkat laptop, dengan prosesor Intel Core i5 2,5 GHz dengan memori 16 Gb. Jika perangkat GPU atau multi-GPU digunakan, kecepatan pemrosesan dan kecepatan model akan meningkat secara signifikan.



## BAB V

### PENUTUP

#### 5.1. Kesimpulan

Model CNN dengan *transfer learning* dapat melakukan klasifikasi sampah medis dengan baik berkinerja baik. Penelitian ini mampu mengidentifikasi fokus sampah yang lebih berbahaya, yaitu sampah medis kelas tajam. Hal ini penting karena sampah kelas tajam memiliki pengelolaan yang lebih ekstra dan berbahaya. Penelitian ini menghasilkan nilai *precision* 100% untuk semua model pada kelas non tajam dan nilai *recall* 100% untuk semua model pada kelas tajam. Untuk memahami kinerja masing-masing model, VGG16 mampu memprediksi 49 kelas non tajam dengan benar. Dan ResNet50 bekerja dengan baik mampu memprediksi 54 kelas non tajam dengan benar. Hal ini dibuktikan dengan model VGG16 menghasilkan nilai akurasi terendah 96,39% dan nilai akurasi tertinggi dicapai model ResNet50 mencapai 99,40%. Perbandingan kinerja masing-masing model CNN dilihat dari jumlah parameter dan waktu yang dibutuhkan. MobileNetV2 membutuhkan parameter yang terkecil yaitu 24 juta parameter sedangkan model VGG19 membutuhkan parameter paling banyak yaitu 143 juta parameter. Dengan dataset *self-provided*, perbandingan 5 arsitektur CNN pada dataset menunjukkan bahwa ResNet50 membutuhkan kecepatan pelatihan 946,64 detik dengan jumlah parameter 25.687.938 yang lebih kecil dari VGG16, VGG19, InceptionV3, dan MobileNetV2. Berdasarkan penghitungan *confusion matrix*, model ResNet50

mendapatkan nilai akurasi 99,40%, sensitivitas 98,18%, dan spesifisitas 100% lebih signifikan dari eksperimen sebelumnya.

### 5.2. Saran

Dataset dengan jumlah yang besar tentu akan menghasilkan kinerja yang lebih baik. Saat ini pandemi Covid-19 memasuki tahun ketiga, ketersediaan berbagai macam dataset bisa menjadi pilihan. Sampah medis yang bercampur di tempat sampah memungkinkan satu frame terdapat banyak objek didalamnya, untuk itu teknik *preprocessing* yang lain dengan metode lain dapat dilakukan penelitian selanjutnya.

## **DAFTAR PUSTAKA**

- Abela, A., & Gatt, T. (2021). Using Class Activation Maps on Deep Neural Networks to Localise Waste Classifications. *2021 IEEE 19th World Symposium on Applied Machine Intelligence and Informatics (SAMI)*, 000143–000148. <https://doi.org/10.1109/SAMI50585.2021.9378662>
- Adedeji, O., & Wang, Z. (2019). Intelligent Waste Classification System Using Deep Learning Convolutional Neural Network. *Procedia Manufacturing*, 35, 607–612. <https://doi.org/10.1016/j.promfg.2019.05.086>
- Adhi Setiawan. (2021). Augmentasi Data Pada Computer Vision. *Data Folks Indonesia*.
- Ahmed, L., Ahmad, K., Said, N., Qolomany, B., Qadir, J., & Al-Fuqaha, A. (2020). Active Learning Based Federated Learning for Waste and Natural Disaster Image Classification. *IEEE Access*, 8, 208518–208531. <https://doi.org/10.1109/ACCESS.2020.3038676>
- Altikat, A., Gulbe, A., & Altikat, S. (2021). Intelligent solid waste classification using deep convolutional neural networks. *International Journal of Environmental Science and Technology*. <https://doi.org/10.1007/s13762-021-03179-4>
- Awe, O., Mengistu, R., & Sreedhar, V. (t.t.). *Final Report: Smart Trash Net: Waste Localization and Classification*. 6.
- Azis, F. A., Suhaimi, H., & Abas, E. (2020). Waste Classification using Convolutional Neural Network. *Proceedings of the 2020 2nd International Conference on Information Technology and Computer Communications*,

- 9–13. <https://doi.org/10.1145/3417473.3417474>
- Behera, S. K., Y, A. B. S., L, V., G, S., C, H. N., & J, S. P. (2020). AI Based Waste Classifier With Thermo-Rapid Composting. *2020 International Conference on Power, Energy, Control and Transmission Systems (ICPECTS)*, 1–4. <https://doi.org/10.1109/ICPECTS49113.2020.9337012>
- Bian, X., Chen, Y., Wang, S., Cheng, F., & Cao, H. (2021). Medical Waste Classification System Based on OpenCV and SSD-MobileNet for 5G. *2021 IEEE Wireless Communications and Networking Conference Workshops (WCNCW)*, 1–6. <https://doi.org/10.1109/WCNCW49093.2021.9420036>
- Bobulski, J., & Kubanek, M. (2019). Waste Classification System Using Image Processing and Convolutional Neural Networks. Dalam I. Rojas, G. Joya, & A. Catala (Ed.), *Advances in Computational Intelligence* (Vol. 11507, hlm. 350–361). Springer International Publishing. [https://doi.org/10.1007/978-3-030-20518-8\\_30](https://doi.org/10.1007/978-3-030-20518-8_30)
- Chen, J., Mao, J., Thiel, C., & Wang, Y. (2020). iWaste: Video-Based Medical Waste Detection and Classification. *2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, 5794–5797. <https://doi.org/10.1109/EMBC44109.2020.9175645>
- Chen, Y., Sun, J., Bi, S., Meng, C., & Guo, F. (2021). Multi-objective solid waste classification and identification model based on transfer learning method. *Journal of Material Cycles and Waste Management*, 23(6), 2179–2191. <https://doi.org/10.1007/s10163-021-01283-8>

- Chu, Y., Huang, C., Xie, X., Tan, B., Kamal, S., & Xiong, X. (2018). Multilayer Hybrid Deep-Learning Method for Waste Classification and Recycling. *Computational Intelligence and Neuroscience*, 2018, 1–9. <https://doi.org/10.1155/2018/5060857>
- Delnevo, G., Aguzzi, G., Letizi, S., Luffarelli, M., Petretti, A., & Mirri, S. (2021). Encouraging users in waste sorting using deep neural networks and gamification. *Proceedings of the Conference on Information Technology for Social Good*, 230–235. <https://doi.org/10.1145/3462203.3477056>
- Frost, S., Tor, B., Agrawal, R., & Forbes, A. G. (2019). CompostNet: An Image Classifier for Meal Waste. *2019 IEEE Global Humanitarian Technology Conference (GHTC)*, 1–4. <https://doi.org/10.1109/GHTC46095.2019.9033130>
- Gao, Y., & Mesalam, K. M. (2018). Deep Transfer Learning for Image-Based Structural Damage Recognition: Deep transfer learning for image-based structural damage recognition. *Computer-Aided Civil and Infrastructure Engineering*, 33(9), 748–768. <https://doi.org/10.1111/mice.12363>
- Gyawali, D., Regmi, A., Shakya, A., Gautam, A., & Shrestha, S. (2020). Comparative Analysis of Multiple Deep CNN Models for Waste Classification. *ArXiv:2004.02168 [CsJ]*. <http://arxiv.org/abs/2004.02168>
- Ha, D., & Tang, Y. (2021). Collective Intelligence for Deep Learning: A Survey of Recent Developments. *arXiv:2111.14377 [csJ]*. <http://arxiv.org/abs/2111.14377>
- Huang, G.-L., He, J., Xu, Z., & Huang, G. (2020). A combination model based on

- transfer learning for waste classification. *Concurrency and Computation: Practice and Experience*, 32(19), e5751. <https://doi.org/10.1002/cpe.5751>
- Huiyu, L., O., O. G., & Kim, S.-H. (2019). Automatic Classifications and Recognition for Recycled Garbage by Utilizing Deep Learning Technology. *Proceedings of the 2019 7th International Conference on Information Technology: IoT and Smart City*, 1–4. <https://doi.org/10.1145/3377170.3377190>
- Irawansyah Putra, T., & Setyowati, N. (2019). Identifikasi Jenis dan Pengelolaan Limbah Bahan Berbahaya dan Beracun Rumah Tangga: Studi Kasus Kelurahan Pasar Tais Kecamatan Seluma Kabupaten Seluma. *NATURALIS – Jurnal Penelitian Pengelolaan Sumberdaya Alam dan Lingkungan*, Volume 8 Nomor 2(Oktober 2019). [https://r.search.yahoo.com/\\_ylt=AwrXgqrXULNhvg0AGgdP5At.;\\_ylu=Y29sbwMEcG9zAzUEdnRpZAMEc2VjA3Ny/RV=2/RE=1639170391/RO=10/RU=https%3a%2f%2fejournal.unib.ac.id%2findex.php%2fnaturalis%2fparticle%2fdownload%2f9209%2f4527/RK=2/RS=6\\_8\\_NblKbYj6arsq3kVZU8uJFvE-](https://r.search.yahoo.com/_ylt=AwrXgqrXULNhvg0AGgdP5At.;_ylu=Y29sbwMEcG9zAzUEdnRpZAMEc2VjA3Ny/RV=2/RE=1639170391/RO=10/RU=https%3a%2f%2fejournal.unib.ac.id%2findex.php%2fnaturalis%2fparticle%2fdownload%2f9209%2f4527/RK=2/RS=6_8_NblKbYj6arsq3kVZU8uJFvE-)
- Jha, B. K., G, S. G., & R, V. K. (2021). E-Commerce Product Image Classification using Transfer Learning. *2021 5th International Conference on Computing Methodologies and Communication (ICCMC)*, 904–912. <https://doi.org/10.1109/ICCMC51019.2021.9418371>
- Kampffmeyer, M., Salberg, A.-B., & Jenssen, R. (2018). Urban Land Cover Classification With Missing Data Modalities Using Deep Convolutional

- Neural Networks. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(6), 1758–1768.  
<https://doi.org/10.1109/JSTARS.2018.2834961>
- Lee, C.-Y., Gallagher, P. W., & Tu, Z. (2015). Generalizing Pooling Functions in Convolutional Neural Networks: Mixed, Gated, and Tree. *arXiv:1509.08985 [cs, stat]*. <http://arxiv.org/abs/1509.08985>
- Li, S., Yan, M., & Xu, J. (2020). Garbage object recognition and classification based on Mask Scoring RCNN. *2020 International Conference on Culture-Oriented Science & Technology (ICCST)*, 54–58.  
<https://doi.org/10.1109/ICCST50977.2020.90016>
- Longo, E., Sahin, F. A., Redondi, A. E. C., Bolzan, P., Bianchini, M., & Maffei, S. (2021). Take the trash out... To the edge. Creating a Smart Waste Bin based on 5G Multi-access Edge Computing. *Proceedings of the Conference on Information Technology for Social Good*, 55–60.  
<https://doi.org/10.1145/3462203.3475921>
- Mao, W.-L., Chen, W.-C., Wang, C.-T., & Lin, Y.-H. (2021). Recycling waste classification using optimized convolutional neural network. *Resources, Conservation and Recycling*, 164, 105132.  
<https://doi.org/10.1016/j.resconrec.2020.105132>
- Meng, S., & Chu, W.-T. (2020). A Study of Garbage Classification with Convolutional Neural Networks. *2020 Indo – Taiwan 2nd International Conference on Computing, Analytics and Networks (Indo-Taiwan ICAN)*, 152–157. <https://doi.org/10.1109/Indo-TaiwanICAN48429.2020.9181311>

- Nandhini, S., Mrinal, S. S., Balachandran, N., Suryanarayana, K., & Ram, D. S. H. (2019). Electronically assisted automatic waste segregation. *2019 3rd International Conference on Trends in Electronics and Informatics (ICOEI)*, 846–850. <https://doi.org/10.1109/ICOEI2019.8862666>
- O'Shea, K., & Nash, R. (2015). An Introduction to Convolutional Neural Networks. *arXiv:1511.08458 [cs]*. <http://arxiv.org/abs/1511.08458>
- Pamintuan, M., Mantilla, S. M., Reyes, H., & Samonte, M. J. (2019). i-BIN: An Intelligent Trash Bin for Automatic Waste Segregation and Monitoring System. *2019 IEEE 11th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment, and Management (HNICEM)*, 1–5. <https://doi.org/10.1109/HNICEM48295.2019.9072787>
- Rawat, W., & Wang, Z. (2017). Deep Convolutional Neural Networks for Image Classification: A Comprehensive Review. *Neural Computation*, 29(9), 2352–2449. [https://doi.org/10.1162/neco\\_a\\_00990](https://doi.org/10.1162/neco_a_00990)
- Rismiyati, Endah, S. N., Khadijah, & Shiddiq, I. N. (2020). Xception Architecture Transfer Learning for Garbage Classification. *2020 4th International Conference on Informatics and Computational Sciences (ICICoS)*, 1–4. <https://doi.org/10.1109/ICICoS51170.2020.9299017>
- Ruiz, V., Sánchez, Á., Vélez, J. F., & Raducanu, B. (2019). Automatic Image-Based Waste Classification. Dalam J. M. Ferrández Vicente, J. R. Álvarez-Sánchez, F. de la Paz López, J. Toledo Moreo, & H. Adeli (Ed.), *From Bioinspired Systems and Biomedical Applications to Machine Learning*

- (Vol. 11487, hlm. 422–431). Springer International Publishing.  
[https://doi.org/10.1007/978-3-030-19651-6\\_41](https://doi.org/10.1007/978-3-030-19651-6_41)
- Sarang Narkhede. (2018). Understanding Confusion Matrix. *Towards Data Science*. <https://towardsdatascience.com/understanding-confusion-matrix-a9ad42dcfd62>
- Sheng, T. J., Islam, M. S., Misran, N., Baharuddin, M. H., Arshad, H., Islam, Md. R., Chowdhury, M. E. H., Rmili, H., & Islami, M. T. (2020). An Internet of Things Based Smart Waste Management System Using LoRa and Tensorflow Deep Learning Model. *IEEE Access*, 8, 148793–148811.  
<https://doi.org/10.1109/ACCESS.2020.3016255>
- Song, F., Zhang, Y., & Zhang, J. (2020). Optimization of CNN-based Garbage Classification Model. *Proceedings of the 4th International Conference on Computer Science and Application Engineering*, 1–5.  
<https://doi.org/10.1145/3424978.3425089>
- Syeda Farha Shazmeen, S. F. S. (2013). Performance Evaluation of Different Data Mining Classification Algorithm and Predictive Analysis. *IOSR Journal of Computer Engineering*, 10(6), 1–6. <https://doi.org/10.9790/0661-1060106>
- Tehrani, A., & Karbasi, H. (2017). A novel integration of hyper-spectral imaging and neural networks to process waste electrical and electronic plastics. *2017 IEEE Conference on Technologies for Sustainability (SusTech)*, 1–5.  
<https://doi.org/10.1109/SusTech.2017.8333533>
- Thokrairak, S., Thibuy, K., & Jitngernmadan, P. (2020). Valuable Waste Classification Modeling based on SSD-MobileNet. *2020 - 5th*

- International Conference on Information Technology (InCIT)*, 228–232.  
<https://doi.org/10.1109/InCIT50588.2020.9310928>
- Toğaçar, M., Ergen, B., & Cömert, Z. (2020). Waste classification using AutoEncoder network with integrated feature selection method in convolutional neural network models. *Measurement*, 153, 107459.  
<https://doi.org/10.1016/j.measurement.2019.107459>
- Wang, C., Qin, J., Qu, C., Ran, X., Liu, C., & Chen, B. (2021). A smart municipal waste management system based on deep-learning and Internet of Things. *Waste Management*, 135, 20–29.  
<https://doi.org/10.1016/j.wasman.2021.08.028>
- Wang, H., Li, Y., Dang, L. M., Ko, J., Han, D., & Moon, H. (2020). Smartphone-based bulky waste classification using convolutional neural networks. *Multimedia Tools and Applications*, 79(39–40), 29411–29431.  
<https://doi.org/10.1007/s11042-020-09571-5>
- Wang, Y., Zhao, W. J., Xu, J., & Hong, R. (2020). Recyclable Waste Identification Using CNN Image Recognition and Gaussian Clustering. *arXiv:2011.01353 [cs]*. <http://arxiv.org/abs/2011.01353>
- Zhang, Q., Yang, Q., Zhang, X., Bao, Q., Su, J., & Liu, X. (2021). Waste image classification based on transfer learning and convolutional neural network. *Waste Management*, 135, 150–157.  
<https://doi.org/10.1016/j.wasman.2021.08.038>
- Zhang, Q., Zhang, X., Mu, X., Wang, Z., Tian, R., Wang, X., & Liu, X. (2021). Recyclable waste image recognition based on deep learning. *Resources*,

*Conservation and Recycling*, 171, 105636.

<https://doi.org/10.1016/j.resconrec.2021.105636>

Zhang, S., Chen, Y., Yang, Z., & Gong, H. (2021). Computer Vision Based Two-stage Waste Recognition-Retrieval Algorithm for Waste Classification.

*Resources, Conservation and Recycling*, 169, 105543.

<https://doi.org/10.1016/j.resconrec.2021.105543>



## LAMPIRAN

