

TESIS

**KLASIFIKASI SAMPAH BOTOL PLASTIK DAN KALENG
MENGGUNAKAN ALGORITMA RESNET50 DAN SQUEEZENET1.1**



Disusun oleh:

Nama : Khaerunnisa Hanapi
NIM : 19.77.1219
Konsentrasi : Business Intelligence

**PROGRAM STUDI S2 TEKNIK INFORMATIKA
PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA
2023**

TESIS

**KLASIFIKASI SAMPAH BOTOL PLASTIK DAN KALENG
MENGGUNAKAN ALGORITMA RESNET50 DAN SQUEEZENET1.1**

**CLASSIFICATION WASTE OF PLASTIC BOTTLES AND CAN USING
RESNET-50 AND SQUEEZENET 1.1 ALGORITHM**

Diajukan untuk memenuhi salah satu syarat memperoleh derajat Magister



Disusun oleh:

Nama : Khaerunnisa Hanapi
NIM : 19.77.1219
Konsentrasi : Business Intelligence

**PROGRAM STUDI S2 TEKNIK INFORMATIKA
PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA
2023**

HALAMAN PENGESAHAN

**KLASIFIKASI SAMPAH BOTOL PLASTIK DAN KALENG MENGGUNAKAN
ALGORITMA RESNET50 DAN SQUEEZENET1.1**

**CLASSIFICATION WASTE OF PLASTIC BOTTLES AND CAN USING
RESNET-50 AND SQUEEZENET 1.1 ALGORITHM**

Dipersiapkan dan Disusun oleh

Khaerunnisa Hanapi

19.77.1219

Telah Diujikan dan Dipertahankan dalam Sidang Ujian Tesis
Program Studi S2 Teknik Informatika
Program Pascasarjana Universitas AMIKOM Yogyakarta
pada hari Rabu, 7 Juni 2023

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

Yogyakarta, 7 Juni 2023

Rektor

Prof. Dr. M. Suvanto, M.M.

NIK. 190302001

HALAMAN PERSETUJUAN

KLASIFIKASI SAMPAH BOTOL PLASTIK DAN KALENG MENGGUNAKAN ALGORITMA RESNET50 DAN SQUEEZENET1.1

CLASSIFICATION WASTE OF PLASTIC BOTTLE AND CAN USING RESNET-50 AND SQUEEZENET 1.1 ALGORITHM

Dipersiapkan dan Disusun oleh

Khaerunnisa Hanapi

19.77.1219

Telah Diujikan dan Dipertahankan dalam Sidang Ujian Tesis
Program Studi S2 Teknik Informatika
Program Pascasarjana Universitas AMIKOM Yogyakarta
pada hari Rabu, 7 Juni 2023

Pembimbing Utama

Anggota Tim Pengaji

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

Dr. Kumara Ari Yuana, S.T., M.T.
NIK. 190302575

Pembimbing Pendamping

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

Anggit Dwi Hartanto, M.Kom
NIK. 190302163

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

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

Yogyakarta, 7 Juni 2023
Direktur Program Pascasarjana

Dr. Kusrini, M.Kom.
NIK. 190302106

HALAMAN PERNYATAAN KEASLIAN TESIS

Yang bertandatangan di bawah ini,

Nama mahasiswa : Khaerunnisa Hanapi
NIM : 19.77.1219
Konsentrasi : Business Intelligence

Menyatakan bahwa Tesis dengan judul berikut:

Tuliskan Judul Tesis Bahasa Indonesia

Dosen Pembimbing Utama : Dr. Arief Setyanto, S.Si, M.T
Dosen Pembimbing Pendamping : Anggit Dwi Hartanto, 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 pengaruh dan disebutkan dalam Daftar Pustaka pada karya tulis ini
4. Perangkat lunak yang digunakan dalam penelitian ini sebelumnya 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, 7 Juni 2023

Yang Menyatakan,



Khaerunnisa Hanapi

HALAMAN PERSEMBAHAN

Saya persembahkan untuk Ibu saya yang sudah menyertai perjalanan thesis ini dengan doa sehingga dapat selesai dengan baik. Suamiku yang selalu menyemangati, saudara serta rekan-rekan dari Universitas Amikom Yogyakarta, terima kasih semuanya. Semoga apa yang peneliti berikan bisa bermanfaat untuk semua orang.



HALAMAN MOTTO

"Menuntut ilmu adalah takwa. Menyampaikan ilmu adalah ibadah. Mengulang-ulang ilmu adalah zikir. Mencari ilmu adalah jihad." – Abu Hamid Al Ghazali.

"Tidak ada kesuksesan tanpa kerja keras. Tidak ada keberhasilan tanpa kebersamaan. Tidak ada kemudahan tanpa doa." – Ridwan Kamil.



KATA PENGANTAR

Puji syukur kehadirat Allah SWT karena atas rahmat-Nya penulis dapat menyelesaikan tesis ini dengan baik. Sholawat serta salam penulis sampaikan kepada nabi besar Muhammad SAW. Alhamdulillah penulis dapat menyelesaikan tesis dengan judul “Klasifikasi Sampah Botol Plastik Dan Kaleng Menggunakan Algoritma Resnet 50 Dan SqueezeNet 1.1”.

Penulis menyadari bahwa penyusunan tesis ini masih jauh dari kata sempurna. Keterbatasan pengetahuan dan kemampuan yang dimiliki serta berbagai hambatan dalam proses pembuatan tesis ini. Namun berkat usaha, do'a, bimbingan, dan kerja keras dari berbagai pihak, penulis dapat menyelesaikan tesis ini dengan baik. Keberhasilan ini tak lepas dari dosen pembimbing dan pendamping dalam membimbing dan menyusun laporan tesis. Oleh karena itu pada kesempatan ini izinkan penulis mengucapkan terima kasih kepada:

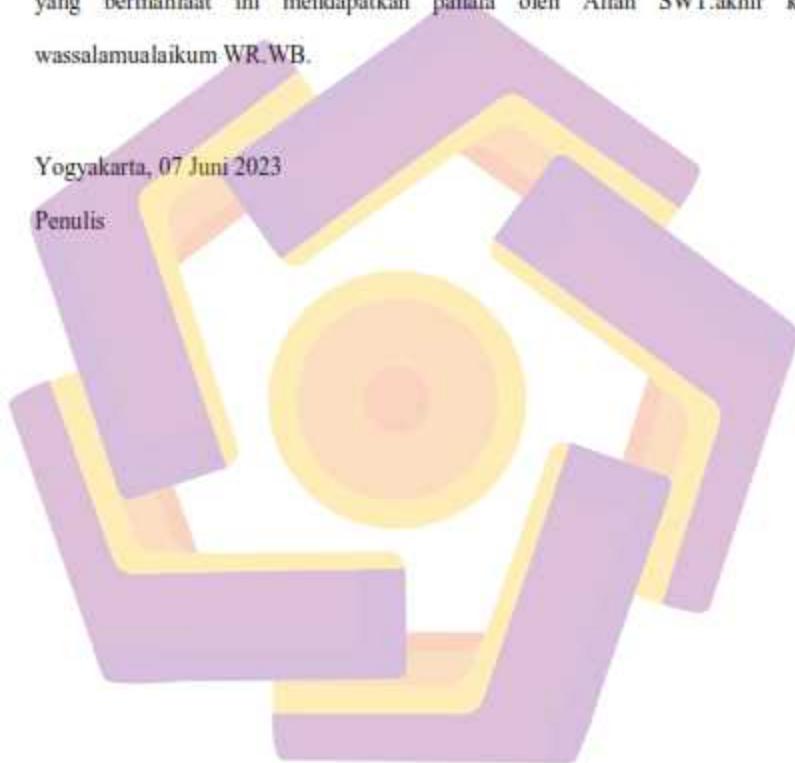
1. Bapak Dr. Arief Setyanto S.Si., M.T. dan Bapak Anggit Dw Hartanto, M.Kom selaku dosen pembimbing yang telah membimbing penulis dan memberi masukan dalam penyusunan tesis ini.
2. Tim dosen penguji telah memberikan masukan untuk kemajuan tesis ini dan memberikan arahan untuk penelitian selanjutnya.
3. Bapak dan Ibu dosen jurusan Magister Teknik Informatika Universitas AMIKOM Yogyakarta yang telah memberikan ilmu dan pengalaman yang sangat bermanfaat.

4. Terima kasih juga kepada Mama, suami dan saudara yang memberikan support dan do'a kepada peneliti agar bisa menyelesaikan tesis ini.

Sekian dari peneliti yang singkat ini semoga apa yang peneliti kerjakan bisa bermanfaat buat banyak orang dan mahasiswa Amikom Yogyakarta. Semoga ilmu yang bermanfaat ini mendapatkan pahala oleh Allah SWT.akhir kata wassalamualaikum WR.WB.

Yogyakarta, 07 Juni 2023

Penulis

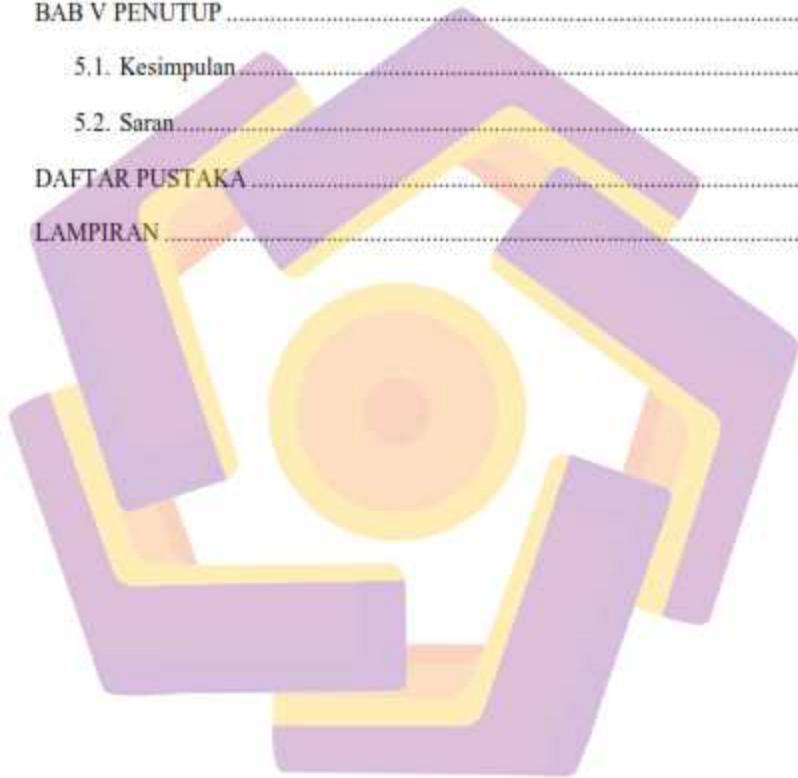


DAFTAR ISI

HALAMAN JUDUL	ii
HALAMAN PENGESAHAN	iii
HALAMAN PERSETUJUAN	iv
HALAMAN PERNYATAAN KEASLIAN TESIS	v
HALAMAN PERSEMBAHAN	vi
HALAMAN MOTTO	vii
KATA PENGANTAR	viii
DAFTAR ISI	x
DAFTAR TABEL	xiii
DAFTAR GAMBAR	xiv
INTISARI	xv
<i>ABSTRACT</i>	xvi
BAB I PENDAHULUAN	1
1.1. Latar Belakang Masalah	1
1.2. Rumusan Masalah	7
1.3. Batasan Masalah	7
1.4. Tujuan Penelitian	8
1.5. Manfaat Penelitian	8
BAB II TINJAUAN PUSTAKA	9
2.1. Tinjauan Pustaka	9
2.2. Keaslian Penelitian	15

2.3. Landasan Teori.....	22
2.3.1. Convolutional Neural Network	22
2.3.2. Resnet 50.....	23
2.3.3. SqueezeNet 1.1.....	24
BAB III METODE PENELITIAN	26
3.1. Jenis, Sifat, dan Pendekatan Penelitian.....	26
3.2. Metode Pengumpulan Data.....	26
3.3. Metode Analisis Data.....	27
3.4. Alur Penelitian.....	28
BAB IV HASIL PENELITIAN DAN PEMBAHASAN.....	30
4.1. Analisis Pengumpulan Data	30
4.1.1. Dataset.....	30
4.1.2. Pengumpulan Data	32
4.1.3. Preprocessing Data.....	33
4.1.4. Pembagian Dataset	34
4.2. Pemodelan	35
4.2.1. Proses Training Model	35
4.2.2. Visualisasi Data Train	37
4.2.3. Inisialisasi Model	38
4.2.4. Pengujian & Evaluasi Model.....	39
4.3. Skenario Pengujian & Klasifikasi 2 Kelas	40
4.3.1. Pengujian & Evaluasi 2 Kelas Resnet 50	40
4.3.2. Pengujian & Evaluasi 2 Kelas SqueezeNet 1.1	42

4.4. Skenario Pengujian & Klasifikasi 4 Kelas	44
4.3.1. Pengujian & Evaluasi 2 Kelas Resnet 50	44
4.3.2. Pengujian & Evaluasi 2 Kelas SqueezeNet 1.1	46
4.5. Analisis Hasil.....	48
BAB V PENUTUP	52
5.1. Kesimpulan.....	52
5.2. Saran.....	52
DAFTAR PUSTAKA.....	53
LAMPIRAN	58



DAFTAR TABEL

Tabel 2.1. Matriks literatur review dan posisi penelitian Klasifikasi Sampah Botol Plastik Dan Kaleng Menggunakan Algoritma Resnet50 Dan SqueezeNet 1.1.	15
Tabel 4.1. Konfigurasi hyperparameter	40
Tabel 4.2. Hasil pengujian klasifikasi 2 kelas Resnet 50.....	41
Tabel 4.3. Confusion matriks akurasi tertinggi resnet 50.....	41
Tabel 4.4. Hasil pengujian klasifikasi 2 kelas SqueezeNet 1.1.....	42
Tabel 4.5. Confusion matriks akurasi tertinggi SqueezeNet 1.1	43
Tabel 4.6. Hasil evaluasi klasifikasi 4 kelas Resnet 50	44
Tabel 4.7. Akurasi data testing tiap label kelas	45
Tabel 4.8. Confusion matriks akurasi 4 kelas resnet 50.....	45
Tabel 4.9. Hasil evaluasi klasifikasi 4 kelas SqueezeNet 1.1	46
Tabel 4.10. Akurasi data testing tiap label kelas	47
Tabel 4.11. Confusion matriks akurasi 4 kelas SqueezeNet 1.1	47
Tabel 4.12. Hasil pengujian algoritma SqueezeNet 1.1.....	49
Tabel 4.13. Hasil Pengujian algoritma Resnet 50	49

DAFTAR GAMBAR

Gambar 2.1. Resnet 50 arsitektur	23
Gambar 2.2. Squeezezenet 1.1 arsitektur	25
Gambar 3.1. Alur Penelitian.....	28
Gambar 4.1. Sampel gambar empty bottle.....	31
Gambar 4.2. Sampel gambar label bottle.....	31
Gambar 4.3. Sampel gambar empty can	31
Gambar 4.4. Sampel gambar label can	31
Gambar 4.5. Sampel data validation can.....	32
Gambar 4.6. Sampel data validation bottle	32
Gambar 4.7. Output visualisasi data train	38
Gambar 4.8. Grafik model accuracy Resnet 50 2 kelas	41
Gambar 4.9. Grafik model loss Resnet 50 2 kelas.....	42
Gambar 4.10. Grafik model accuracy Squeezezenet 1.1 2 kelas	43
Gambar 4.11. Grafik model loss Squeezezenet 1.1 2.kelas.....	43
Gambar 4.12. Grafik model accuracy Resnet 50 4 kelas.....	45
Gambar 4.13. Grafik model loss Resnet 50 4 kelas.....	46
Gambar 4.14. Grafik model accuracy Squeezezenet 1.1 4 kelas	47
Gambar 4.15. Grafik model loss Squeezezenet 1.1 4 kelas.....	48
Gambar 4.16. Data botol plastik 1500ml & kaleng	50
Gambar 4.17. Data botol plastik dan kaleng	51

INTISARI

Masalah sampah dewasa ini merupakan masalah yang crucial, apalagi diikuti oleh kepadatan penduduk, dan regulasi pemerintah serta faktor-faktor lainnya yang sedikit banyak mempengaruhi bagaimana sampah dapat dikelola secara baik dan benar. Hal ini sangat menentukan dan berefek pada kelayakan hidup orang-orang lingkungan sekitar dan menciptakan lingkungan yang bersih serta menata sampah yang sangat susah didaur ulang. Plastik dan kaleng merupakan tipe sampah yang sangat susah didaur ulang, oleh karenanya dengan menggunakan reverse vending machine permasalahan tersebut dapat diatasi. Pada position paper kali ini yang diusulkan adalah membandingkan algoritma SqueezeNet 1.1 dan ResNet-50 untuk dapat mengklasifikasikan sampah plastik dan kaleng dengan berbagai ukuran. Dari hasil simulasi algoritma tersebut dengan data set yang ada, diperoleh model terbaik untuk klasifikasi 2 kelas dan 4 kelas yaitu SqueezeNet 1.1 dengan akurasi sebesar 96.13% dan 90.7%.

Kata kunci: machine learning, deep learning, convolutional neural network, waste classification, squeezeNet 1.1, resnet50



ABSTRACT

Waste problem is one of crucial global issue. Population growth, government regulations, people behavior and many other factors affect the waste management problem. This has a huge impact on the livability of the people in the neighborhood and maintaining a clean environment as well as managing waste is particularly challenging. Plastics and cans are the types of waste that are very difficult to recycle, so by using a reverse vending machine (RVM) these problems can be overcome. The critical point of RVM is the ability to recognize the type of waste. Deep learning has been successfully overperforms in many computer vision tasks, more specifically image recognition. SqueezeNet and ResNet are two convolutional based deep learning algorithms. This study aims to compare the performance of two methods for plastic bottles and cans classification using SqueezeNet 1.1 and ResNet-50. From this research results, the best model with highest accuracy for classification of 2 classes and 4 classes are SqueezeNet 1.1 with 96.13% and 90.7%.

Keywords: machine learning, deep learning, convolutional neural network, waste classification, squeezeNet 1.1, resnet50



BAB I

PENDAHULUAN

1.1. Latar Belakang Masalah

Reduce, reuse, recycle (3R) sampah adalah kampanye yang bertujuan mengurangi produksi sampah. Sebuah riset yang dilakukan oleh Universitas Georgia, Amerika Serikat menunjukkan Indonesia menempati peringkat kedua sebagai negara yang menghasilkan sampah terbesar (Jambeck et al., 2015) dan tidak mengelola sampah dengan baik di dunia . Berdasarkan data Badan Pusat Statistik (BPS) tahun 2021 jumlah sampah di Indonesia mencapai 66 juta ton per tahun. Pada tahun 2021, komposisi sampah yang dihasilkan mencapai 54% untuk sampah organik dan 46% untuk sampah non organic, dimana sampah plastic mencapai 17,2% dari total sampah non organik.

Penggunaan plastik yang massal disebabkan oleh sifat plastic yang dapat dibentuk ke berbagai bentuk saat terpapar panas dan tekanan. Banyaknya produk yang terbuat dari plastik karena harganya yang murah serta tahan lama membuat produksi sampah tidak terkendali. Industri minuman memakai plastik sebagai wadah dan banyak yang tidak bisa digunakan kembali. Polusi plastik menjadi masalah lingkungan dalam beberapa tahun terakhir dan menjadi perhatian penggiat lingkungan dalam menciptakan alternatif mengurangi sampah melihat tingginya sampah yang dibuang ke laut di Indonesia, maka dari itu kami mengajukan penelitian ini dengan harapan model yang kami usulkan dapat meningkatkan akurasi deteksi botol plastic dan kaleng pada system RVM.

Sampah plastik yang tidak terkelola dengan baik membawa dampak yang sangat besar pada kerusakan lingkungan hidup tercermin dari sifatnya yang sulit terurai, dan proses dekomposisi sampah plastic secara sempurna memakan waktu 100-500 tahun (Karuniastuti, n.d.). Sedangkan membakar sampah di ruang terbuka akan mengeluarkan emisi Polychlorinated Dibenzo-p-dioxins yang merupakan salah satu zat beracun (Lemieux et al., 2000). Mendaur ulang sampah plastik menjadi cara paling efektif karena susahnya plastik diuraikan di alam.

Pemisahan dan daur ulang sampah diperlukan untuk masyarakat yang berkelanjutan. Saat ini, penerapan ITC (misalnya menggunakan teknologi dan perangkat seperti smart sensor, platform cloud atau Internet of Things) ke Smart City dalam tugas klasifikasi sampah otomatis dapat secara signifikan meningkatkan efisiensi dalam proses ini (S. Sudha et al., n.d.). Pengklasifikasian ini dapat dilakukan berdasarkan jenis sampah, yaitu sifat biodegradable dari limbah, atau aspek lainnya (Yang & Thung, n.d.). Di samping itu, organisasi anti-membuang sampah sembarangan dan pemerintah kota di seluruh dunia menilai perkotaan kebersihan melalui human audit (Mittal et al., 2016). Masyarakat khususnya di negara berkembang harus menjadi garda utama dalam pemilahan sampah. Lokasi dan kuantifikasi limbah adalah langkah penting untuk meningkatkan kebersihan kota, yang bisa menjadi kesehatan masalah di negara-negara padat penduduk seperti Indonesia (Wahyudin & Afriansyah, 2020). Salah satu metode untuk mengurangi wadah minuman di tempat sampah dengan menerapkan Reverse Vending Machine (RVM).

Dasar dari sistem RVM adalah pengenalan objek. Pengenalan objek adalah proses mengidentifikasi objek dalam citra digital dengan set fitur dan label yang dikenali. Manusia memiliki kemampuan untuk mengenali objek dalam jumlah besar dalam gambar dengan mudah, meskipun objek tampil dengan perspektif atau sudut tertentu. Secara logika, objek dikenali dari beberapa perspektif berbeda (misal warna, ukuran, bentuk atau tampilan), dalam ukuran yang berbeda. Metode pengenalan objek diaplikasikan dalam kehidupan sehari-hari seperti sistem pengenalan optical character (Kashioka et al., 1976)(Ejiri, 2007), chip defect finding systems, satellite data processing, dan image data mining yang diaplikasikan di industri dan komersial (Andreopoulos & Tsotsos, 2013).

Hal inilah yang menjadi dasar pengembangan sistem RVM. RVM bekerja dengan menerima botol dan kaleng bekas lalu menggantinya dengan koin ataupun kupon. RVM dirancang dan diterapkan di AS, Cina, dan Jepang sejak 2007. Bagian terpenting dari desain RVM adalah mengidentifikasi botol plastik dan kaleng (Sakr et al., 2016). Karena tidak adanya sensor untuk identifikasi botol plastik, beberapa teknik lain seperti computer vision, pencocokan kode batang maupun sound recognition digunakan. Demikian pula, karena aluminium tidak menunjukkan sifat magnet, kaleng aluminium dideteksi menggunakan eddy current sensors (Dhulekar et al., 2018).

Teknologi RVM telah banyak dikembangkan oleh peneliti-peneliti sebelumnya dari machine learning hingga deep learning, pada machine learning (T. Yoo et al., 2021) menggunakan CNN ensemble dengan menggabungkan dua model CNN untuk mengklasifikasi botol plastik dengan citra atas (top view) dan citra

depan (front view), (J. Yoo et al., 2022) menggunakan CNN untuk mendeteksi botol kosong dan tanpa label. Untuk solusi menggunakan deep learning, (Zia et al., 2022) membangun RVM yang murah dari segi harga dan ringan dalam proses identifikasi menggunakan MobileNet untuk kemudian mengklasifikasi dataset yang telah dikumpulkan.

(Mariya et al., n.d.) membuat teknologi RVM menggunakan Tensorflow untuk mendeteksi botol plastic dengan metode klasifikasi yang digunakan adalah R- CNN, Fast RCNN, Faster-RCNN, dimana hasil klasifikasi ini akan menghasilkan ID unik dan poin yang dapat diakumulasi untuk ditukarkan dengan voucher belanja. (Kokoulin & Kiryanov, n.d.) menawarkan solusi berbeda dengan membangun RVM menggunakan perangkat IoT sehingga hasil deteksi botol plastic, dan aluminium terhubung ke smartphone pengguna.

Meskipun penelitian sebelumnya telah menggunakan Resnet 50 dan SqueezeNet 1.1 untuk mendeteksi sampah botol namun tujuan penelitian ini adalah membuat sebuah pemodelan baru dengan transfer learning Resnet 50 dan SqueezeNet 1.1 untuk mendapatkan akurasi tertinggi menggunakan data sampah botol plastic dan kaleng dengan berbagai bentuk dan ukuran. Hal ini dikarenakan penelitian-penelitian sebelumnya lebih berfokus pada klasifikasi sampah botol plastik bersih dan tanpa cairan. Posisi penelitian ini khususnya adalah bagaimana menumbuhkan minat masyarakat untuk memilah sampah konsumsi jika penelitian ini diimplementasikan ke masyarakat, diharapkan lebih mudah untuk diterima. Penelitian berfokus pada mendeteksi sampah botol plastic dan kaleng yang memiliki label dan cairan maupun tidak dimana ukuran botol plastik yang

digunakan adalah 250 ml, 330 ml, 500 ml, 1000 ml, 1500 ml, 2000 ml dan 330ml untuk kaleng minuman.

Selain itu, sistem pembuangan sampah yang ada di Indonesia membutuhkan tenaga kerja manual untuk memilah sampah. Dengan 278 juta populasi di Indonesia (2021), hanya mengandalkan segregasi manual tentu tidak sehat. Hal ini akan mengarah ke lingkungan tidak sehat dan menimbulkan bahaya bagi pengepul atau pekerja kebersihan. Tujuan penelitian ini kemudian selain untuk masyarakat umum adalah menciptakan sistem otomatis pemilah sampah untuk memudahkan pemilahan limbah plastik dalam hal ini botol bekas minuman yang banyak digunakan dalam kehidupan sehari-hari.

Sistem pengolahan sampah menjadi solusi penanganan sampah khususnya di negara berkembang dan padat penduduk seperti Indonesia. Penelitian mengenai manajemen sampah telah banyak dilakukan dikarenakan kepadatan penduduk yang bertambah pesat menyebabkan lahan pembuangan sampah berkurang sehingga masyarakat lebih sering membuang sampah di tempat yang tidak seharusnya seperti sungai dan laut. Sampah yang telah diteliti sebelumnya (Ruiz et al., 2019) dan digunakan pada penelitian ini adalah sampah botol plastik dan kaleng. Penelitian tersebut menggunakan dataset Trashnet untuk melatih dan membandingkan beberapa metode Deep Learning dalam klasifikasi jenis sampah secara otomatis. Metode yang digunakan adalah VGG, Inception dan Resnet dengan hasil terbaik dicapai kombinasi Inception-Resnet yang memperoleh akurasi sebesar 88.6%. Resnet 50 juga digunakan oleh peneliti sebelumnya (Lin et al., 2023) yang mengadopsi transfer learning Resnet 50 menjadi MSWNet untuk melakukan

klasifikasi terhadap MSW (Municipal Solid Waste) dataset. Hasil yang diperoleh untuk klasifikasi MSW adalah 88.5% untuk Resnet 50 dan 93.5% untuk MSWNet model. Penelitian mengenai klasifikasi sampah menggunakan metode SqueezeNet telah dilakukan (Rzechowski, n.d.) yang mengevaluasi tiga dataset sampah dengan MobileNet, Resnet dan SqueezeNet, dimana SqueezeNet mendapat kombinasi terbaik untuk kecepatan, akurasi dan memory pada penerapan real world system namun dalam hal akurasi sendiri SqueezeNet tertinggal dengan akurasi 80% dibandingkan MobileNet dan Resnet50 yang mencapai akurasi 89%.

Algoritma yang digunakan pada penelitian ini adalah klasifikasi Resnet 50 dan SqueezeNet 1.1. Resnet50 dipilih berdasarkan penelitian sebelumnya yang memperoleh hasil cukup baik (Zia et al., 2022) dengan nilai akurasi mencapai 95.4%, sedangkan SqueezeNet dipilih karena penelitian (T. Yoo et al., 2021b) mendapat nilai akurasi rata-rata diatas 95% untuk klasifikasi objek baik dari top view, front view, maupun kombinasi keduanya. Kedua algoritma tersebut dipilih untuk diteliti karena kemampuannya untuk komputasi dengan cepat, mengingat bentuk botol plastik dan kaleng yang akan berbeda-beda terkait penanganan tiap orang sehingga model ini akan sering melakukan training seiring bertambahnya dataset sehingga dibutuhkan komputasi yang cepat dan ringan.

Penelitian ini bermaksud membandingkan performa squeezeNet 1.1 dan resnet 50 dalam melakukan klasifikasi sampah botol plastik dan kaleng. Penelitian ini hanya menggunakan image, tanpa secara khusus mendeteksi label pada citra yang diamati untuk mengatasi keterbatasan pada beberapa botol yang tidak

mencantumkan label ataupun barcode. Penelitian ini hanya didesain menggunakan kamera, tanpa sensor lain seperti eddy current sensor.

1.2. Rumusan Masalah

Berdasarkan latar belakang permasalahan di atas, rumusan masalah yang akan dibahas pada penelitian ini adalah sebagai berikut:

- a. Bagaimana hasil klasifikasi sampah botol plastik dan kaleng menggunakan algoritma Resnet 50 dan SqueezeNet 1.1 untuk pemodelan pada penelitian ini?
- b. Apakah kondisi botol yang berisi cairan dan memiliki label mempengaruhi pendekstrian botol?

1.3. Batasan Masalah

Beberapa hal yang menjadi Batasan masalah dalam penelitian ini adalah sebagai berikut:

- a. Data *train* yang digunakan adalah dataset public yang diambil dari website Kaggle.
- b. Dataset berupa citra digital dari prototype *Reverse Vending Machine* dan gambar yang diambil manual menggunakan kamera biasa.
- c. Data uji yang digunakan adalah data asli sampah plastic dan kaleng yang dikumpulkan oleh peneliti.
- d. Jumlah dataset berjumlah 4.168 gambar yang terdiri dari 3.999 botol plastic berbagai ukuran dari 250 ml sampai 2000 ml dan 169 gambar kaleng minuman.

- e. Hasil penelitian mendapatkan akurasi terbaik untuk pemodelan klasifikasi gambar sampah botol plastic dan kaleng.
- f. Fokus penelitian adalah pengukuran akurasi dari algoritma Resnet-50 dan Squeeze net 1.1.

1.4. Tujuan Penelitian

- a. Memperoleh algoritma yang paling sesuai dengan pemodelan yang diajukan berdasarkan nilai akurasi terbaik.
- b. Menganalisa apakah botol yang berisi cairan dan memiliki label dengan botol kosong tanpa label mempengaruhi nilai akurasi dari metode yang diusulkan. Solusi yang ditawarkan untuk menangani permasalahan yang dihadapi.

1.5. Manfaat Penelitian

Manfaat penelitian yang diharapkan adalah:

- a. Pemerintah dan perusahaan, dapat menggunakan pemodelan ini untuk meningkatkan akurasi Reverse Vending Machine yang dimiliki khususnya untuk botol plastic dan botol kaleng.
- b. Masyarakat, dapat membangun Reverse Vending machine sederhana yang murah, cepat dan ringan.

BAB II

TINJAUAN PUSTAKA

2.1. Tinjauan Pustaka

Berbagai metode klasifikasi sampah botol plastic dan kaleng telah diajukan oleh penulis-penulis sebelumnya. (Dhulekar et al., 2018) Membuat Bottle Recycle Machine (BRM) untuk mengidentifikasi botol plastic berdasarkan bentuk, sisi dan warna botol menggunakan algoritma machine learning yang kemudian dari karakteristik tersebut akan menjadi fitur-fitur CNN. Dalam penelitian ini, citra digital botol akan diakuisisi dan fitur yang diekstraksi akan diklasifikasi menggunakan tonovel classifier. Setelah botol diidentifikasi dan diklasifikasikan, botol disortir menggunakan slider crank sesuai jenis bahan botol. Botol yang disortir kemudian didaur ulang menggunakan perakitan mekanis. Desain BRM yang diusulkan memberikan identifikasi botol yang akurat dan daur ulang yang efektif dengan biaya rendah.

(Korucu et al., 2016) membuat penelitian yang bertujuan bahwa pengenalan suara dapat digunakan untuk memisahkan jenis dan ukuran sampah kemasan dalam Reverse Vending Machine (RVMs) dengan akurasi yang tinggi. Studi ini merekam suara yang dihasilkan dari tiga jenis dampak fisik pada sampah kemasan dan mengembangkan sistem klasifikasi suara berbasis mesin vektor pendukung (SVM) dan model hidden Markov (HMM) untuk mengklasifikasikan jenis dan ukuran sampah berdasarkan fitur suara. SVM classifier memberikan akurasi 100% untuk data jatuh bebas yang diperoleh oleh kedua mikrofon dinamis dan kondensor pada

tingkat pelatihan 90%. HMM classifier memberikan akurasi 96,5% dan 97,7% untuk mikrofon dinamis dan kondensor, masing-masing, pada kondisi yang diperluas dari pengaturan. Artikel ini juga membahas berbagai studi dan teknik terkait pengenalan suara untuk pengelolaan limbah, termasuk penggunaan model Markov tersembunyi untuk pengenalan gerakan dan ucapan, identifikasi bahan melalui suara, dan potensi pengenalan suara dalam mesin pengambilan kembali untuk pemisahan sumber sampah kemasan. Artikel ini juga membahas implikasi lingkungan dan ekonomi dari sistem pengumpulan dan pengelolaan limbah.

Berbeda dengan (Tur et al., 2019) dalam penelitiannya "Beverage Container Collecting Machine Project" membuat RVM menggunakan algoritma LeNet untuk mengklasifikasi sampah botol plastik dan kaleng minuman. Akurasi yang diperoleh untuk botol plastik adalah 97% dan 83% untuk kaleng minuman.

Penelitian lain Kokoulin (2018), melakukan perbandingan antara LeNet, AlexNet dan SqueezeNet untuk mengidentifikasi botol plastik, kaleng minuman dan fraud pada Reverse Vending Machine yang menggunakan IoT controllers. Hasil yang didapatkan kemudian adalah AlexNet CNN memperoleh akurasi terbaik untuk deteksi botol plastik namun LeNet juga mencapai akurasi yang hampir sama setelah beberapa kali percobaan.

(Ruiz et al., 2019) di tahun berikutnya membuat penelitian mengenai klasifikasi sampah. Penelitian ini membahas penggunaan teknik computer vision dan deep learning untuk mendeteksi dan mengklasifikasikan jenis sampah secara otomatis untuk tujuan daur ulang. Dataset TrashNet digunakan untuk melatih dan membandingkan berbagai arsitektur deep learning, termasuk VGG, Inception, dan

ResNet. Hasil terbaik diperoleh menggunakan model gabungan Inception-ResNet, mencapai akurasi 88,6%. Penelitian ini juga meninjau kembali pekerjaan sebelumnya dalam sistem berbasis gambar untuk klasifikasi sampah dan menguraikan berbagai arsitektur neural deep yang digunakan untuk klasifikasi sampah terwasi. Penelitian ini mengevaluasi penggunaan beberapa arsitektur CNN untuk klasifikasi sampah otomatis. Hasil klasifikasi terbaik dicapai menggunakan arsitektur ResNet dengan akurasi rata-rata 88,66% pada dataset TrashNet. Studi ini juga mencapai hasil terbaik pada dataset yang sama dibandingkan dengan state-of-the-art yang ada. Para penulis menyarankan penelitian masa depan pada pembuatan gambar sintetis yang realistik dengan beberapa jenis sampah untuk melatih model.

Di tahun yang sama (Wachs Lopes et al., n.d.) membuat penelitian yang bertujuan untuk mengusulkan pendekatan deep learning hierarkis untuk mendeteksi dan mengklasifikasikan sampah pada nampan makanan, dengan tujuan untuk mengotomatisasi pengelompokan sampah. Selain itu, penelitian ini juga memperkenalkan dataset baru yang disebut Labeled Waste in the Wild, yang berisi 1002 gambar nampan makanan bekas yang diambil di lingkungan dunia nyata dan diannotasi dengan 19 kelas yang berbeda yang mewakili bentuk dan bahan dari objek sampah.

Penelitian dari Mariya D (2020) meneliti Tensorflow model untuk mengklasifikasi botol plastic pada prototype RVM yang dibangun. Penelitian ini memfokuskan pengembangan perangkat keras dari RVM dengan menggunakan sensor pada inlet mesin yang akan terbuka saat botol plastic yang dimasukkan, dan tetap tertutup jika yang dimasukkan adalah botol lain selain plastik. Untuk

algoritma yang digunakan adalah R-CNN, Fast RCNN, Faster-RCNN, dan Retina Net namun tidak dijelaskan akurasi yang didapatkan dari pemodelan-pemodelan tersebut.

Di tahun yang sama, (El hakim et al., 2020) menggunakan metode Euclidean Distance pada RVM untuk mendekripsi sampah botol berdasarkan 3 parameter yaitu berat, nilai logam, dan warna. Pengenalan dan pemilahannya menggunakan tiga sensor yaitu Sensor Proximity Induktif untuk mendekripsi logam dan non logam, LDR untuk mendekripsi warna botol, dan menghitung berat botol menggunakan Loadcell. Akurasi tertinggi pembacaan sensor terhadap berat botol sebesar 99,28%, sedangkan deteksi logam dan non logam mencapai akurasi 100%.

Meskipun berbeda dari objek penelitian yang akan diusulkan, namun Penelitian (Awaludin et al., 2022) ini membahas penggunaan teknologi Convolutional Neural Network untuk mengidentifikasi dan mengklasifikasikan penyakit pada daun kopi. Studi ini berfokus pada arsitektur ResNet-50 dan mengukur kinerjanya menggunakan Confusion Matrix. Studi dilakukan dengan dua kasus, yaitu klasifikasi kelas biner dan klasifikasi multikelas. Hasilnya menunjukkan bahwa dalam kasus akurasi kelas biner mencapai 92,68% dan F1-Score mencapai 92,88%, sedangkan dalam kasus akurasi multikelas hanya mencapai 88,98% dan F1-Score mencapai 88,44%. Penelitian ini membahas proses pengembangan model pembelajaran mesin untuk mengklasifikasikan daun kopi sehat dan sakit menggunakan algoritma ResNet-50. Dataset yang digunakan dalam studi diperoleh dari repositori Mendeley Data dan mengalami pra-pemrosesan, termasuk pelabelan data, segmentasi, augmentasi data, dan resize data. Model

dilatih dan diuji menggunakan skenario yang berbeda, dan hasilnya dievaluasi menggunakan confusion matrix dan metrik kinerja seperti akurasi, presisi, recall, spesifitas, dan F1-score. Skenario terbaik mencapai akurasi 92,68% dan F1-score 92,88%. Penelitian ini membahas penggunaan model ResNet-50 untuk klasifikasi biner dan multikelas penyakit daun kopi. Klasifikasi biner mencapai akurasi 92,68% dan F1-score 92,88%, sedangkan klasifikasi multikelas mencapai akurasi hingga 88,98% dan F1-score 88,44%. Penelitian ini menyarankan bahwa kualitas dataset yang lebih baik atau modifikasi model ResNet-50 dapat meningkatkan kinerja klasifikasi multikelas.

Penelitian terbaru dari (Lin et al., 2023) yang mengadopsi transfer learning dari Resnet 50 untuk pemilahan sampah perkotaan. Hasil dari penelitian ini adalah bahwa metode deep machine learning MSWNet yang menggunakan transfer learning berdasarkan ResNet 50 dapat digunakan untuk pengelompokan sampah padat perkotaan (MSW) dengan hasil yang lebih baik dibandingkan dengan ResNet 50. MSWNet menunjukkan kinerja yang lebih baik dalam klasifikasi MSW dalam hal sensitivitas, presisi, F1-score, akurasi, dan AUC. Selain itu, MSWNet juga dapat memberikan penjelasan visual tentang fitur-fitur yang digunakan dalam klasifikasi MSW. Hasil penelitian ini dapat dijadikan referensi untuk membangun model klasifikasi MSW dengan deep learning.

(Parmonangan R. Togatorop & Ahmad Fauzi, 2022) Penelitian ini membahas pengembangan model klasifikasi menggunakan SqueezeNet untuk ekstraksi fitur dan Naïve Bayes dan Support Vector Machine untuk proses klasifikasi guna menentukan apakah seseorang mengenakan masker wajah atau

tidak. Studi ini bertujuan untuk menyediakan alat untuk mendeteksi individu yang tidak mengenakan masker untuk membantu mencegah penyebaran COVID-19. Penelitian ini juga memberikan gambaran singkat tentang SqueezeNet, Naïve Bayes, dan Support Vector Machine. Studi ini menggunakan SqueezeNet untuk ekstraksi fitur untuk mengklasifikasikan gambar wajah dengan dan tanpa masker. Model dievaluasi menggunakan Naïve Bayes dan SVM, mencapai akurasi, presisi, dan recall yang tinggi. Hasil evaluasi model dengan 10-Fold Validation, untuk Naïve Bayes diperoleh akurasi 0.958, presisi 0.981, dan recall 0.938. Sedangkan pemodelan dengan menggunakan SVM, akurasi sebesar 0.992, presisi 0.994, dan recall 0.990. Studi menyimpulkan bahwa model ini efektif untuk deteksi masker.

2.2. Keaslian Penelitian

Tabel 2.1. Matriks literatur review dan posisi penelitian
Klasifikasi Sampah Botol Plastik dan Kaleng menggunakan Algoritma Resnet-50 dan SqueezeNet 1.1

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
1	Reverse Vending Machine for Plastic Bottle Recycling	Deena Mariya, Jaseela Usman, Elsha Nimmay Mathew, Hasna PH, IJCST, 2020	Menggunakan Tensorflow model untuk mendeteksi botol plastik pada prototype RVM yang dibuat	Penelitian ini memfokuskan pada implementasi hardwarenya, namun metode yang digunakan untuk melakukan klasifikasi adalah R-CNN, Fast RCNN, Faster-RCNN	Tidak ada akurasi dan hanya mendeteksi botol plastik.	Penelitian ini menggunakan CNN untuk mendeteksi botol plastik. Penelitian yang akan dibangun menggunakan algoritma Resnet50 & SqueezeNet untuk mendeteksi botol plastik dan kaleng yang berisi cairan dan tidak serta mencari model mana yang menghasilkan akurasi terbaik.
2	Development of Bottle Recycling Machine	Dhulekar P, Gandhe S, Mahajan U, ICACCT, 2018	Membuat Bottle Recycle Machine (BRM) menggunakan image processing menggantikan barcode scanning	Penelitian ini menggunakan algoritma tonovel classifier untuk mengklasifikasi botol plastik dan kaleng minuman, akurasi nya adalah 80%	Tidak dapat mendeteksi botol yang tidak didefinisikan ulang di dalam dataset.	Penelitian ini memfokuskan pada implementasi algoritma Tonovel Classifier untuk mendeteksi botol plastik.

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
	using Machine Learning Algorithm					Penelitian yang akan dibangun menggunakan algoritma resnet50 dan squeezeNet 1.1 untuk mendeteksi botol plastik dan kaleng yang berisi cairan dan kosong dalam berbagai bentuk dan ukuran
3	Beverage Container Collecting Machine Project	Tur et al., IOP Conference Series: Earth and Environmental Science, 2019	Menciptakan RVM yang low cost dan efisien dalam mengumpulkan data.	Penelitian ini menggunakan algoritma CNN LeNet untuk mengklasifikasi botol plastik dan kaleng minuman, akurasinya adalah 87% dan 93%		<p>Penelitian memfokuskan pada pendekstian menggunakan CNN LeNet pada botol kosong.</p> <p>Penelitian yang akan dibangun mendeteksi botol menggunakan algoritma Resnet50 & SqueezeNet 1.1 pada botol kosong maupun yang memiliki isi.</p>

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
4	Convolutional Neural Networks Application in Plastic Waste Recognition and Sorting	Kokoulin et al., IEEE, 2018	Penerapan IoT dan CNN pada RVM	<p>Penelitian ini menggunakan beberapa algoritma dengan akurasi seperti berikut:</p> <ul style="list-style-type: none"> • CNN+LeNet: 80% • CNN + AlexNet: 93% • CNN+SqueezeNet: 87% 		<p>Penelitian yang akan dibangun menggunakan algoritma resnet50 dan squeezeNet 1.1 untuk mendekripsi botol plastik dan kaleng yang berisi cairan dan kosong.</p>
5	A study challenges of adoption of reverse vending machine: A case of Bengaluru, India	S.K. Paramitha, et al, Proceeding of the World Conference on Waste Management, 2019	Mengetahui respon masyarakat pada adopsi RVM untuk menangani permasalahan sampah di Bengaluru. Metode yang digunakan adalah hipotesis wilayah yang terdiri dari; awareness, convenience, incentives & involvement yang di pengaruh oleh, age, gender, marital status, occupation (S.K et al., 2019)	<p>Sebuah studi bagaimana menyiapkan pertumbuhan sampah plastik di Bengaluru India menggunakan metode RVM dengan kompensasi coupon bagi yang mengumpulkannya.</p>	<p>Study terbatas di Bengaluru India yang tentu akan berbeda di negara lainnya, apalagi seperti negara maju yang demografi dan peran pemerintah sangat aktif untuk 'memaksa' masyarakat agar mengikuti aturan mengenai sampah plastik</p>	<p>Penelitian ini berfokus pada respon masyarakat pada adopsi RVM untuk menangani permasalahan sampah di Bengalure.</p> <p>Penelitian yang akan dibangun fokus pada metode yang akan digunakan pada RVM untuk mendapat akurasi deteksi sampah yang lebih baik menggunakan algoritma resnet50 dan squeezeNet 1.1 untuk</p>

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
...	Development of reverse vending machine framework for implementation to a standard recycle bin	Tomari, et al., Procedia Computer Science , 2017	Bagaimana pendekatan teknologi RVM menggunakan mikrokontroler untuk bisa membedakan type plastik dan non plastik pada bak sampah (Tomari et al., 2017)	Pendekatan teknologi RVM pada bak sampah menghasilkan tingkat keberhasilan rata-rata 97% dan waktu operasi rata-rata 35 detik. Untuk akurasi berat menghasilkan $\pm 5,5$ gr berdasarkan percobaan dari berbagai titik pada baki timbangan.	Penelitian hanya menggunakan sample yang sangat sedikit dengan pengguna yang terbatas.	Penelitian menggunakan teknologi RVM standar yang sesuai untuk ditempatkan pada bak sampah umum. Penelitian yang akan dibangun menggunakan algoritma resnet50 dan squeezenet 1.1 untuk mendeteksi botol plastic dan kaleng yang berisi cairan dan kosong. Pemodelan yang akan dibangun menghasilkan akurasi yang lebih baik.
	The optical method for the plastic for the plastic waste	Kokoulin, International Multidisciplinary Scientific	Bagaimana metode pengenalan sampah plastik, kaleng dan non plastik bisa bisa		Perlu diujicoba dengan algoritma lainnya atau hybrid algoritma	Penelitian yang akan dibangun menggunakan algoritma resnet50 dan

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
	recognition and sorting in a reverse vending machine	GeoConference : SGEM, 2019	dipraktekan melalui metode optikal dengan algoritma CNN menggunakan bahasa Phyton dan C++			squeezenet 1.1 untuk mendeteksi botol plastik dan kaleng yang berisi cairan dan kosong.
	Pengenalan dan Pemilahan Botol Kosong pada Reverse Vending Machine menggunakan metode Euclidean Distance	El Hakim et al, Journal of Innovation Information Technology and Application (JINITA),2020	Bagaimana metode Euclidean Distance mendeteksi sampah botol plastik dan kaleng berdasarkan nilai logam, berat dan warna botol.	Pengenalan menggunakan sensor berat menghasilkan akurasi 99,28% sedangkan berdasarkan nilai logam memperoleh hasil 100%	Sistem masih belum dapat membedakan sampah botol yang masih terdapat cairan didalamnya atau tidak, sehingga jika sampah botol ini masih terdapat cairan didalamnya, maka akan mempengaruhi dari point yang didapatkan oleh pengguna	Penelitian ini menggunakan sensor berat, nilai logam dan warna untuk memilah botol plastik dan kaleng Penelitian yang akan dibangun menggunakan citra digital untuk mendeteksi jenis botol baik plastik maupun kaleng menggunakan algoritma Resnet50 dan SqueezeNet1.1
	Clean Bottle: A reverse vending machine	Yoo J et al, Proceedings of the 8th IIAE, 2022	Penelitian ini membangun RVM untuk mendeteksi botol bersih tanpa segel	Akurasi terbaik yang diperoleh dalam penelitian ini adalah 99,3% dengan menggunakan	Pengujian yang dilakukan masih sangat terbatas	Penelitian ini menggunakan CNN untuk mendeteksi botol plastik bersih dari segel dan isi.

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
	thatdetects clean PET bottles with machine learning.		dan isi menggunakan algoritma CNN.	filter convolutional 16,32, dan 64.		Penelitian yang akan dibangun dapat mendeteksi berbagai bentuk botol plastik dan kaleng menggunakan algoritma Resnet50 dan SqueezeNet1.1
	Automatic Image-Based Waste Classification	Victoria Ruiz et al., IWINAC, 2019	Pendekatan deep learning hierarkis untuk mendeteksi dan mengklasifikasikan sampah pada nampakan makanan menggunakan beberapa model CNN	Akurasi terbaik diperoleh Resnet dengan nilai 88,6%	Pengujian menggunakan banyak objek dalam 1 gambar.	Penelitian ini menggunakan CNN untuk mendeteksi sampah pada nampakan.
	MSWNet: A visual deep machine	Lin K, Zhao Y, et al,	Mengadopsi metode deep machine learning MSWNet yang	MSWNet menunjukkan kinerja yang lebih baik dalam klasifikasi	Data yang digunakan pada penelitian ini bukan berasal dari	Data yang digunakan pada penelitian ini adalah data sampah asli yang

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
	learning method adopting transfer learning based upon ResNet 50 for municipal solid waste sorting	Front. Environ. Sci. Eng. 2023	menggunakan transfer learning berdasarkan ResNet 50 dapat digunakan untuk pengelompokan sampah padat perkotaan (MSW)	MSW dalam hal sensitivitas (93.50%), precision (93.40%), F1-score (93.40%), accuracy (93.50%) and AUC (92.00%)	sampah sebenarnya sehingga implementasi dalam real world system mungkin akan mengubah akurasi yang diperoleh.	dikumpulkan sehingga penerapan dalam real world system tidak akan jauh berbeda dengan pengujian yang dilakukan.
	One-dimensional convolutional neural networks for acoustic wastesorting	Lu G, Wang Y, Yang H et al, Journal of Cleaner Production, 2020	Mengklasifikasi sampah berdasarkan data akustik menggunakan CNN 1 dimensi untuk mengekstraksi fitur. Metode eksperimen ortogonal diterapkan untuk mengoptimalkan tiga parameter kunci dari struktur CNN 1D	Eksperimen menunjukkan bahwa metode yang diusulkan dapat mencapai akurasi klasifikasi 92.40% dalam waktu singkat.	Dataset yang masih terbatas baik dari jumlah sampel tiap kategori maupun jenis sampah.	Penelitian yang akan dibangun menggunakan citra sampah sehingga akurasi yang diperoleh lebih baik

2.3. Landasan Teori

Tujuan penelitian ini adalah membandingkan dua model yang pada penelitian sebelumnya memiliki akurasi yang baik terhadap klasifikasi gambar. Klasifikasi gambar yang akan dianalisa akurasinya akan dibagi menjadi dua kelas yaitu botol dan kaleng. Data yang digunakan adalah dataset dari Kaggle, dan model yang diajukan untuk klasifikasi adalah ResNet 50 & SqueezeNet 1.1 (Iandola et al., 2016).

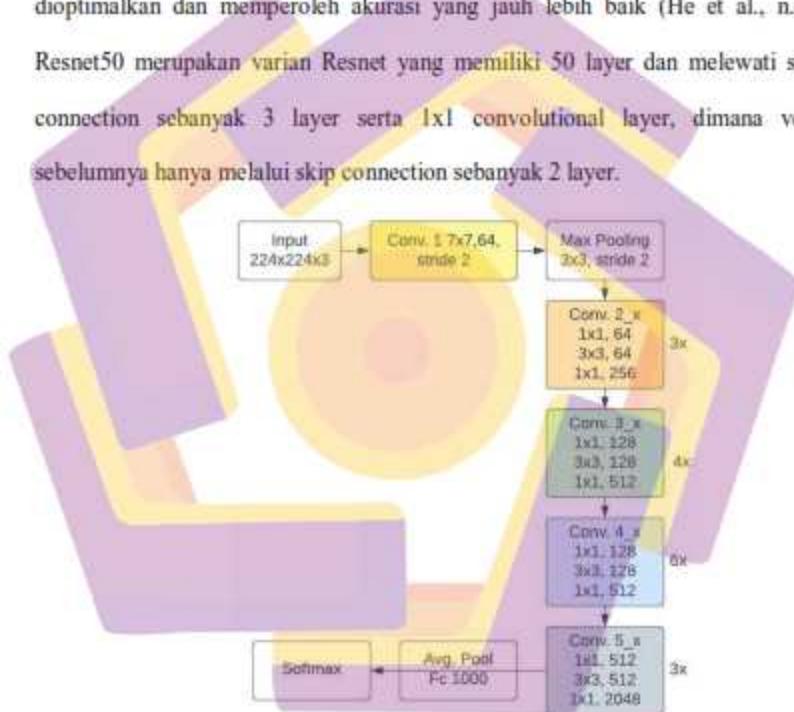
2.3.1. Convolutional Neural Network (CNN)

Beberapa tahun terakhir, Convolutional Neural Network (CNN) mencapai hasil baik dalam klasifikasi gambar. Hal ini dikarenakan CNN menunjukkan keunggulan luar biasa pada pengaplikasian terhadap pendekatan machine learning (Krizhevsky et al., 2017). CNN dibangun dengan mengadopsi cara kerja otak manusia dan memiliki struktur tiruan dari otak manusia (Sun et al., 2020). Dengan struktur tersebut, CNN dapat melakukan ekstraksi fitur dengan lebih detail dari sebuah citra dan hasil pembelajaran yang tersimpan dapat dijadikan acuan untuk klasifikasi selanjutnya dikarenakan adanya parameter weight dan bias di dalam strukturnya.

Struktur CNN secara umum terdiri dari tiga komponen utama, yaitu convolutional layer, pooling layer dan full connection layer. Ketiga komponen ini kemudian dapat dikombinasi hingga membentuk model baru sesuai kebutuhan dan tujuan masing-masing. Salah satu contoh modifikasi arsitektur CNN adalah ResNet 50(He et al., n.d.) yang kami ajukan.

2.3.2. Resnet 50

Resnet atau Residual Network merupakan model yang dapat melatih jaringan saraf yang sangat dalam dengan lebih dari 150 lapisan. Arsitektur sebelum Resnet tidak dapat melakukan pelatihan yang sangat dalam disebabkan oleh hilangnya gradien. Arsitektur Resnet menunjukkan bahwa jaringan saraf dapat dioptimalkan dan memperoleh akurasi yang jauh lebih baik (He et al., n.d.). Resnet50 merupakan varian Resnet yang memiliki 50 layer dan melewati skip connection sebanyak 3 layer serta 1×1 convolutional layer, dimana versi sebelumnya hanya melalui skip connection sebanyak 2 layer.



Gambar 2.1. Resnet50 Architecture

Gambar 1 merupakan arsitektur Resnet-50 dimana tahap pertama yang akan dilakukan adalah citra memasuki proses pelatihan model pada arsitektur ResNet-50. Pada tahap pertama, citra yang berasal dari layer input di konvolusi pada lapisan

konvolusi dengan ukuran filter 7×7 dan stride 2. Proses tersebut menghasilkan feature map yang akan dinormalisasi oleh Batch Normalization.

Arsitektur ini memiliki banyak lapisan, yang memungkinkan untuk mengumpulkan informasi lebih lanjut dari citra yang diberikan dan menciptakan model yang lebih baik. ResNet50 juga menggunakan teknik penghalusan yang disebut penghalusan residual untuk menghindari masalah pengetatan (overfitting). Teknik ini memungkinkan untuk menghemat waktu dan meminimalkan jumlah lapisan yang diperlukan tanpa mengorbankan akurasi. Arsitektur ini telah menunjukkan hasil yang luar biasa dalam berbagai aplikasi AI, seperti pengenalan wajah, pengenalan objek, dan pengenalan bahasa alami.

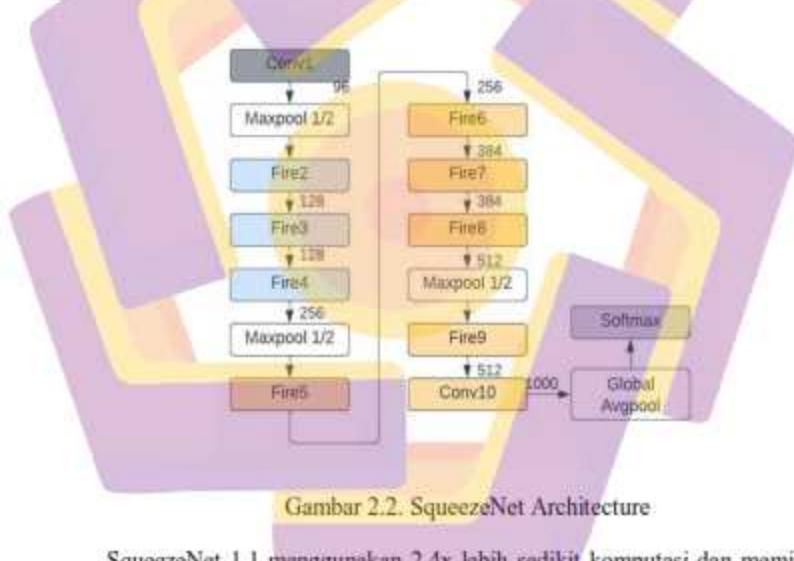
Hasil dari normalisasi selanjutnya masuk ke layer aktivasi, dimana fungsi ReLU digunakan untuk mengubah hasil ekstraksi fitur menjadi non-linier. Tahap selanjutnya output dari fungsi ReLU direduksi pada layer max pooling sebelum diteruskan pada tahap konvolusi kedua. Di antara tahap konvolusi kedua sampai dengan kelima, proses ekstraksi fitur dilakukan oleh kombinasi convolutional block dan identity block. Setelah proses ekstraksi fitur selesai, kemudian feature map diproses ke dalam fully connected layer untuk melakukan proses prediksi dibantu dengan fungsi aktivasi sigmoid.

2.3.3. SqueezeNet 1.1

SqueezeNet (Iandola et al., 2016) adalah jaringan saraf ringan yang mencapai presisi yang sama dengan AlexNet dengan 1/50 jumlah parameter. SqueezeNet terdiri dari banyak modul api, yang merupakan campuran dari lapisan

konvolusi, lapisan sampling bawah, dan pooling rata-rata global, yang menggantikan lapisan koneksi penuh.

Lapisan konvolusi yang terpisah (conv1), delapan modul api (fire2-9), dan lapisan konvolusi lainnya membentuk SqueezeNet (conv10). Dari awal hingga akhir jaringan, jumlah filter modul api meningkat secara progresif. SqueezeNet mengeksekusi max pooling dengan ukuran stride 2 setelah conv1, fire4, fire8, dan conv10 layer. SqueezeNet memiliki dua versi yaitu SqueezeNet 1.0 dan SqueezeNet 1.1 (Liu et al., 2020).



Gambar 2.2. SqueezeNet Architecture

SqueezeNet 1.1 menggunakan 2.4x lebih sedikit komputasi dan memiliki lebih sedikit parameter dibanding versi 1.0 namun tidak mengurangi akurasi yang didapatkan.

BAB III

METODE PENELITIAN

3.1. Jenis, Sifat, dan Pendekatan Penelitian

Penelitian ini menggunakan disiplin ilmu artificial intelligence (AI), dimana pada bidang ilmu ini akan diterapkan sebuah machine learning untuk melakukan klasifikasi pada sampah botol plastic dan kaleng.

Penelitian ini merupakan penelitian eksperimental dengan meneliti tingkat akurasi dari algoritma klasifikasi Resnet50 dan SqueezeNet1.1 dalam mendeteksi botol plastic dan kaleng dari dataset citra botol yang digunakan. Citra botol yang akan dilakukan pengklasifikasian diperoleh dari prototype Reverse Vending Machine.

Sifat penelitian ini dilakukan secara mandiri menggunakan metode deskriptif dari data yang diperoleh. Sedangkan untuk pendekatan menggunakan metode kuantitatif yaitu mengukur tingkat akurasi masing-masing algoritma dari pemodelan ini yaitu algoritma Resnet 50 dan SqueezeNet 1.1.

3.2. Metode Pengumpulan Data

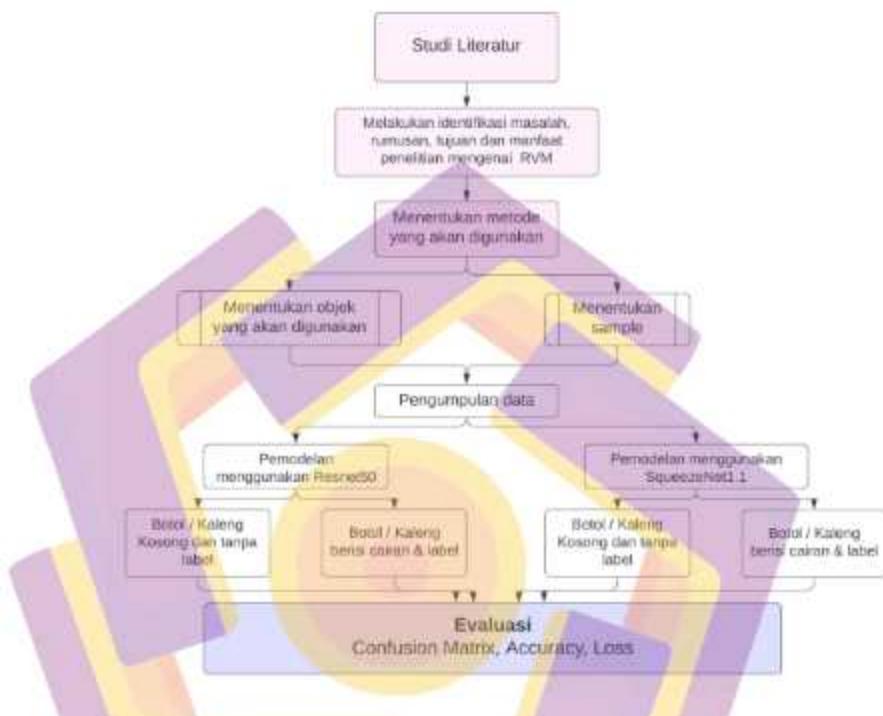
Metode yang digunakan dalam penelitian ini adalah studi dokumen. Metode ini dilakukan untuk mencari data-data mengenai sampah botol plastik dan kaleng yang akan digunakan dalam penelitian.

3.3. Metode Analisis Data

Analisis data dimulai dari dataset yang telah dikumpulkan, langkah pertama adalah menganalisis dataset berdasarkan ukuran dan jenis sampah botol. Untuk botol plastik ukuran yang digunakan adalah 250 ml, 330 ml, 500 ml, 1000 ml, 1500 ml, 2000 ml sedangkan botol kaleng menggunakan ukuran 330ml. Selain ukuran bentuk sampah juga menjadi perhatian guna mendapatkan hasil deteksi terbaik.

Untuk analisis yang kedua yaitu mengetahui algoritma mana yang terbaik, maka akan dilakukan penghitungan akurasi pada masing-masing algoritma. Penghitungan akurasi akan dilakukan menggunakan dataset yang sudah dibuat dengan cara membagi menjadi data training dan data test. Validasi keakuratan pemodelan akan dilakukan menggunakan confusion matrix, serta pengukuran precision dan recall.

3.4. Alur Penelitian



Alur penelitian yang akan dilakukan yaitu sebagai berikut:

1. **Studi literatur**, berisi bagaimana mencari sumber data, contoh data, penentuan objek penelitian dan jenis dataset yang digunakan.
2. **Identifikasi masalah**, dalam proses identifikasi masalah pemilihan dan perumusan masalah serta identifikasi definisi operasional dari masalah yang dihadapi
3. **Penentuan algoritma/metode**, pemilihan algoritma yang relevan atau terkait dengan penelitian terdapat pada tahap ini

- 
4. **Pengumpulan data**, ketika algoritma sudah didapatkan maka selanjutnya bagaimana mengumpulkan data baik dari jenis dataset, jumlah dataset dan variasi dataset yang diperlukan.
 5. **Pemodelan & Klasifikasi**, proses klasifikasi menggunakan metode Resnet50 dan SqueezeNet 1.1 yang dilakukan akan menghasilkan pengelompokan berdasarkan ada tidaknya cairan dan label pada data botol atau kaleng. Pada proses klasifikasi terdapat proses training dan testing, yang mana data training sangat berpengaruh pada hasil dari proses klasifikasi.
 6. **Evaluasi**, dalam kesimpulan terdapat analisis performa yaitu mengukur hasil dari accuracy, loss dan confusion matriks dari penelitian yang telah dilakukan.

BAB IV

HASIL PENELITIAN DAN PEMBAHASAN

4.1. Analisis Pengumpulan Data

4.1.1. Dataset

Pada penelitian ini, dataset terdiri dari 2 sumber, yang pertama dataset publik di website Kaggle dan kedua merupakan dataset yang dikumpulkan dari Google Search dan sampah yang ada disekitar dengan menggunakan kamera ponsel. Dataset berisi 3.999 gambar botol plastic ukuran 250ml hingga 2L dan 169 kaleng minuman yang kemudian dibagi ke dalam 4 kelas berbeda yakni Empty Bottle, Label Bottle, Empty Can dan Label Can.

Dalam hal karakteristik sampah, Gambar 4.1 merupakan contoh sampah botol kelas Empty Bottle dalam berbagai bentuk, botol yang termasuk dalam kelas ini adalah botol bersih yang tidak memiliki label dan tidak berisi cairan. Bentuk maupun cairan pada kelas Label Botol sendiri lebih bervariasi terlihat pada Gambar 4.2 sampel pertama merupakan botol tanpa label berisi cairan bening, kedua botol berlabel dan berisi sedikit cairan berwarna dan sampel ketiga merupakan botol plastik berlabel dan berisi cairan berwarna yang penuh, selain itu botol plastik yang termasuk dalam kelas Label Bottle adalah botol kosong yang memiliki label. Untuk kelas Label Can dan Empty Can perbedaan antar kelas hanya berdasarkan botol kaleng yang berlabel dan kaleng tanpa label / polos seperti sampel pada Gambar 4.3 & 4.4.



Gambar 4.1. Sampel Gambar Empty Bottle



Gambar 4.2. Sampel Gambar Label Bottle



Gambar 4.3. Sampel Gambar Empty Can



Gambar 4.4. Sampel Gambar Label Can

Data yang akan digunakan untuk evaluasi model ResNet50 dan SqueezeNet 1.1 yang telah dilatih sebelumnya adalah data asli yang dimiliki peneliti berisi 39

data botol plastic ukuran 330ml hingga 2L dan 14 data kaleng minuman. Gambar contoh untuk dataset uji dapat dilihat pada Gambar 4.5 dan Gambar 4.6.



Gambar 4.5. Sampel Data Validation Can



Gambar 4.6. Sampel Data Validation Bottle

4.1.2. Pengumpulan Data

Pada penelitian kali ini dataset yang digunakan adalah data yang diambil dari website Kaggle. Dari beberapa dataset yang dikumpulkan selanjutnya akan dipilih gambar-gambar yang sesuai dengan tujuan penelitian. Data yang telah

difilter kemudian akan dilabeli manual mengingat di dalam *machine learning* supervisi diperlukan label pada datanya. Pelabelan data yang telah dikumpulkan kemudian diberi label, Bottle atau Can dan akan dibagi lagi menjadi Empty Bottle, Label Bottle, Empty Can atau Label Can.

4.1.3. Preprocessing Data

Dari data Bottle dan Can yang sudah dilakukan pelabelan selanjutnya akan dilakukan beberapa tahap *preprocessing*. Hal ini dilakukan karena ketidakseimbangan dataset yang dapat menyebabkan overfitting ataupun underfitting pada saat training. Jumlah data Bottle yang digunakan saat training berjumlah 3200 dan data Can hanya 135 gambar, maka dilakukan augmentasi pada data Can untuk menyeimbangkan dataset. Pada data Can dilakukan augmentasi terlebih dahulu sebelum dilakukan training. Augmentasi data yang digunakan adalah rotation sebesar 15 & 30 derajat, vertical flip, horizontal flip, centercrop dan zoom. Hasil dari augmentasi untuk kelas Can diperoleh 810 gambar sehingga dataset training memiliki komposisi 3.999 data Bottle dan 810 data Can. Sedangkan untuk proses training dilakukan beberapa augmentasi data sebagai berikut :

- a) *Random rotation* sebesar 30 derajat akan diterapkan pada data train untuk meningkatkan jumlah data train dan variasi data.
- b) *Random resized crop* bertujuan untuk mengubah ukuran data train ke ukuran 224 sesuai dengan inputan model.
- c) *Vertical flip* diterapkan agar model dapat membaca data yang lebih bervariasi.

Pada data validasi, preprocessing yang digunakan *Resize* dan *Center crop*. Fungsi kedua fitur ini untuk mengubah ukuran data sesuai dengan inputan model yaitu 224, *random rotation* maupun *vertical flip* tidak diterapkan karena pada saat validasi kita ingin model dapat melakukan klasifikasi sesuai bentuk data yang sebenarnya.

4.1.4. Pembagian Dataset

Pada tahap ini data akan dibagi menjadi data *train* dan data *validation*. Data *training* sebesar 80% dari total data baik untuk kelas Bottle maupun kelas Kaleng sedangkan untuk data *validation* sebesar 20%.

Algoritma 2. Database Split

```

1: training_portion = 0.8
2: bottle_train_length = training_portion * len(os.listdir('Dataset/Bottle'))
3: can_train_length = training_portion * len(os.listdir('Dataset/Can'))
```

Algoritma 3. Bottle Data Split

```

1: fileCounter = 0
2: for file in os.listdir('Dataset/Bottle'):
3:
4:     src = os.path.join('Dataset/Bottle', file)
5:     if fileCounter <= bottle_train_length:
6:         dest = bottle_train_dir
7:     else:
8:         dest = bottle_val_dir
9:
10:    shutil.move(src, dest)
11:    fileCounter += 1
12:    print("Move {} from {} to {}".format(file, src, dest))
13:
14: print("DATA BOTTLE TRAIN: {} DATA".format(len(os.listdir(bottle_train_dir))))
15: print("DATA BOTTLE VAL: {} DATA".format(len(os.listdir(bottle_val_dir))))
```

Algoritma 4. Can Data Split

```

1: fileCounter = 0
2: for file in os.listdir('Dataset/Can'):
3:
```

```
4:     src = os.path.join('Dataset/Can', file)
5:     if fileCounter <= can_train_length:
6:         dest = can_train_dir
7:     else:
8:         dest = can_val_dir
9:
10:    shutil.move(src, dest)
11:    fileCounter += 1
12:    print("Move {} from {} to {}".format(file, src, dest))
13:
14: print("DATA CAN TRAIN: {} DATA".format(len(os.listdir(can_train_dir))))
15: print("DATA CAN VAL: {} DATA".format(len(os.listdir(can_val_dir))))
```

4.2. Pemodelan

Pemodelan pada penelitian ini akan dibagi menjadi 2 untuk masing – masing model. Pemodelan pertama akan dilakukan klasifikasi menggunakan dataset yang terdiri dari 2 kelas yaitu Bottle dan Can untuk Resnet50 dan SqueezeNet 1.1. Pemodelan kedua, klasifikasi akan dilakukan menggunakan dataset 4 kelas yaitu Empty Bottle, Label Bottle, Empty Can dan Label Can. Hal ini dilakukan untuk mengetahui apakah pembagian botol / kaleng kosong tanpa cairan dengan botol / kaleng kosong berisi cairan dan memiliki label mempengaruhi hasil klasifikasi pada 2 model yang diusulkan.

4.2.1. Proses Training Model

Tujuan dilakukannya training adalah untuk membentuk model dari Resnet50 maupun SqueezeNet 1.1 yang nantinya akan digunakan sebagai sistem klasifikasi. Sebelum training dijalankan, ada beberapa konfigurasi hyperparameter yang diatur terlebih dahulu. Hal ini dilakukan agar model yang kita gunakan tidak overfitting ataupun underfitting dan memaksimalkan akurasi prediksi model yang

diusulkan. Hyperparameter yang dikonfigurasi antara lain, learning rate, batch size dan 4 macam konfigurasi epoch untuk keperluan investigasi, tertera pada Tabel 4.1.

Tabel 4.1. Konfigurasi hyperparameter.

Learning rate	Batch Size	Epoch
0.001	32	5, 10, 15, 20

Sesuai Tabel 2, proses training dibagi menjadi 5 tahapan epoch dimulai dari 5 sampai dengan 20. Tahap pertama dilakukan proses load dataset Bottle Can sebanyak 3.199 citra ke dalam sistem sebagai data masukan untuk training dan diperkecil menjadi resolusi 224×224 agar komputasi dapat berjalan lebih cepat. Terdapat dua kelas dari dataset yang dijadikan input dalam proses training.

Selanjutnya untuk resnet 50 proses ekstraksi fitur dilakukan dari tahap 1 sampai tahap 5. Pada tahap 1 gambar dikonvolusi oleh convolutional layer dengan ukuran filter 7×7 dan stride 2. Proses ini menghasilkan feature map yang akan dinormalisasi oleh Batch Normalization. Tujuan normalisasi adalah membuat nilai-nilai keluaran dari layer sebelumnya yang bervariasi menjadi 1 skala yang sama dan mempercepat proses training karena beban komputasi berkurang.

Hasil dari normalisasi selanjutnya masuk ke layer aktivasi, didalamnya terdapat ReLU atau Rectified Linear Unit activation function yang digunakan untuk mengubah hasil dari ekstraksi fitur menjadi non-linear. Selanjutnya nilai keluaran dari fungsi aktivasi direduksi oleh maxpooling layer sebelum diteruskan pada tahap 2.

Diantara tahap 2 sampai dengan tahap 5, proses ekstraksi fitur dilakukan oleh kombinasi susunan antara convolutional block dan identity block. Pada blok-

blok tersebut, gambar mengalami pereduksian dan peningkatan dimensi. Hal ini disebabkan oleh tipe arsitektur pada kedua blok tersebut terdiri dari tiga tahapan konvolusi dengan ukuran filter 1×1 , 3×3 dan 1×1 . Tipe arsitektur blok seperti ini dikenal dengan sebutan ‘bottleneck’ dan ditujukan untuk menghemat waktu komputasi. Setelah proses ekstraksi fitur selesai kemudian feature map diproses ke dalam fully connected layer untuk melakukan proses prediksi dibantu dengan fungsi aktivasi sigmoid.

Sedangkan untuk SqueezeNet 1.1 proses ekstraksi fitur dimulai dari convolutional layer dengan ukuran filter 3×3 dan stride 2. Proses ini kemudian dilanjutkan ke max-pooling layer yang berfungsi untuk menghitung nilai maksimum setiap patch pada feature map. Setelah max-pooling layer proses pengujian akan berlanjut ke fire module. Fire module dipilih untuk meminimalkan parameter jaringan dan meningkatkan akurasi. Hasil dari 3 tahap fire module dan max-pooling SqueezeNet akan menghasilkan filter 1×1 pada convolutional dan dilakukan downsampling dilangkah akhir dari arsitektur untuk mendapatkan peta aktivasi yang besar.

4.2.2. Visualisasi Data Train

Baris kode dibawah merupakan fungsi untuk memvisualisasikan dataset yang kita gunakan dalam training. Data yang ditampilkan merupakan dataset yang telah dilakukan augmentasi sebelumnya. Hal ini juga untuk memastikan bahwa dataset yang digunakan telah masuk dalam dataloader.

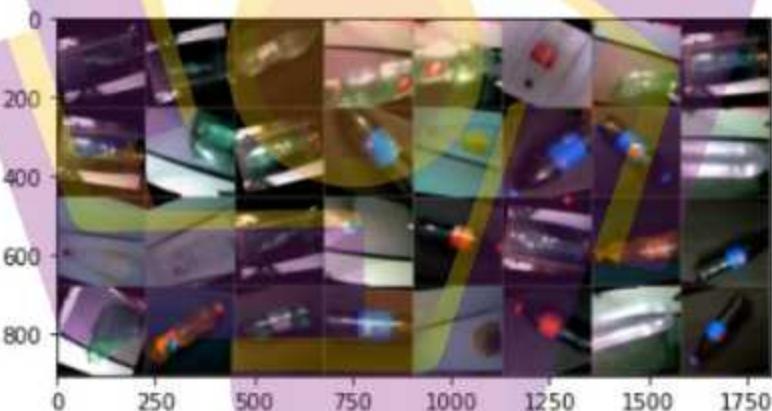
Algoritma 5. Menampilkan beberapa gambar dari data train

```
1: def imshow(inp, title=None):
```

```

2:     """Imshow for Tensor."""
3:     inp = inp.numpy().transpose((1, 2, 0))
4:     mean = np.array([0.485, 0.456, 0.406])
5:     std = np.array([0.229, 0.224, 0.225])
6:     inp = std * inp + mean
7:     inp = np.clip(inp, 0, 1)
8:     plt.imshow(inp)
9:     if title is not None:
10:         plt.title(title)
11:     plt.pause(0.001) # pause a bit so that plots are updated
12:
13: # Get a batch of training data
14: inputs, classes,_ = next(iter(dataloaders['train']))
15:
16: # Make a grid from batch
17: out = torchvision.utils.make_grid(inputs)
18:
19: imshow(out)

```



Gambar 4.7. Output dari fungsi visualisasi data train

4.2.3. Inisialisasi Model

Pada penelitian ini, algoritma yang digunakan adalah model Resnet 50 dan SqueezeNet 1.1 dari library torchvision yang telah dilatih sebelumnya.

Algoritma 6. Inisialisasi Algoritma yang digunakan

```

1: def initialize_model(model_name, num_classes, feature_extract = False, use_pre
trained=True):
2:
3:     model_ft = None
4:     input_size = 0
5:
6:     if model_name == "resnet50":
7:         """
8:             Resnet50
9:             """
10:        model_ft = models.resnet50(pretrained=use_pretrained)
11:        set_parameter_requires_grad(model_ft, feature_extract)
12:        num_ftrs = model_ft.fc.in_features
13:        model_ft.fc = nn.Linear(num_ftrs, num_classes)
14:        input_size = 224
15:
16:    elif model_name == "squeezenet":
17:        """
18:            SqueezeNet
19:            """
20:        model_ft = models.squeezenet1_1(pretrained=use_pretrained)
21:        set_parameter_requires_grad(model_ft, feature_extract)
22:        model_ft.classifier[1] = nn.Conv2d(512, num_classes, kernel_size=(1,1), st
ride=(1,1))
23:        model_ft.num_classes = num_classes
24:        input_size = 224

```

4.2.4. Pengujian dan Evaluasi Model

Pada tahap ini, langkah pertama yang dilakukan adalah menyesuaikan parameter. Optimizer, criterion dan learning rate adalah beberapa parameter yang diatur pada bagian ini. Fungsi parameter agar model yang dilatih menghasilkan akurasi yang baik serta menghindari overfitting maupun hyperparameter.

Algoritma 7. Setting Parameter

```

1: params_to_update = []
2: for name,param in model_ft.named_parameters():
3:     if param.requires_grad == True:
4:         params_to_update.append(param)
5:

```

```

6: optimizer_conv = optim.SGD(params_to_update, lr=0.01, momentum=0.9)
7:
8: criterion = nn.CrossEntropyLoss()
9: # Decay LR by a factor of 0.1 every epoch
    exp_lr_scheduler = lr_scheduler.StepLR(optimizer_conv, step_size=3, gamma=0.1
10: )

```

Algoritma 8. Setting Parameter

```

1 model_ft,acc,loss = train_model(model_ft, criterion, optimizer_conv,
2                                 exp_lr_scheduler, num_epochs=5, is_inception=False)

```

4.3. Skenario Pengujian Klasifikasi 2 Kelas

Pada skenario ini akan diujikan klasifikasi pada 2 kelas data Bottle dan Can menggunakan algoritma Resnet50 dan SqueezeNet 1.1. Pembagian porsi data training dan data testing dibagi menjadi 80% data training dan 20% data testing.

Skenario epoch akan dibagi dalam 4 skenario yaitu 5, 10, 15, dan 20.

4.3.1. Pengujian & Evaluasi Klasifikasi 2 Kelas menggunakan Resnet 50

Berikut adalah hasil dari pengujian model menggunakan algoritma resnet50 untuk melakukan klasifikasi terhadap 2 kelas data dengan 4 skenario epoch yang berbeda-beda.

Tabel 4.2. Hasil pengujian klasifikasi 2 kelas menggunakan Resnet50

Epoch	Train Loss	Validation Loss	Train Accuracy	Val Accuracy	Time
5	0.0091	0.1024	99.76%	96.27%	15m 10s
10	0.0021	0.0783	99.97%	96.75%	27m 33s
15	0.0087	0.1671	99.76%	93.62%	37m 45s
20	0.0012	0.0589	100%	97.59%	54m 34s

Hasil pengujian diatas diperoleh bahwa akurasi tertinggi adalah pada scenario epoch 20 dengan akurasi validasi mencapai 97.59% dengan validation loss 0.0589. Berdasarkan model terbaik tersebut kemudian dilakukan testing dan

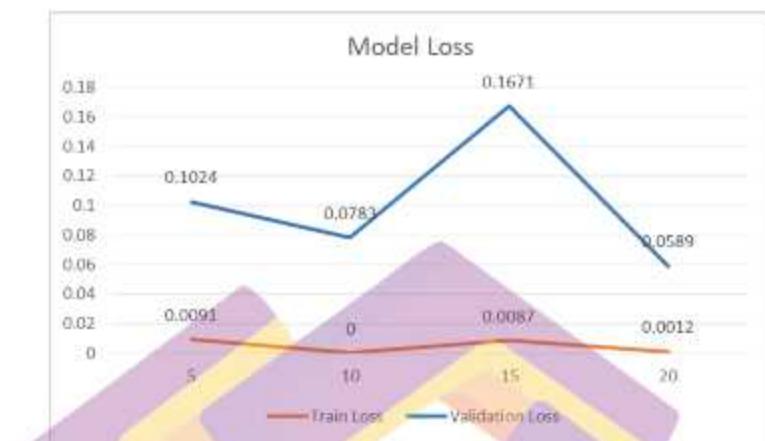
menghasilkan akurasi 93,6%. Tabel 4.2 berisi confusion matrix untuk akurasi tertinggi dari model Resnet 50. Berikut confusion matrix untuk hasil testing Resnet50.

Tabel 4.3. *Confusion Matrix* dengan akurasi tertinggi untuk klasifikasi 2 kelas menggunakan Resnet50

	TRUE	FALSE
TRUE	757	41
FALSE	12	20



Gambar 4.8. Grafik Model Accuracy training Resnet50 Klasifikasi 2 kelas



Gambar 4.9. Grafik Model Loss training Resnet50 Klasifikasi 2 kelas

4.3.2. Pengujian & Evaluasi Klasifikasi 2 Kelas menggunakan SqueezeNet 1.1

Berikut adalah hasil dari pengujian model menggunakan algoritma squeezeenet 1.1 untuk melakukan klasifikasi terhadap 2 kelas data dengan 4 skenario epoch yang berbeda-beda.

Tabel 4.4. Hasil pengujian klasifikasi 2 kelas menggunakan SqueezeNet 1.1

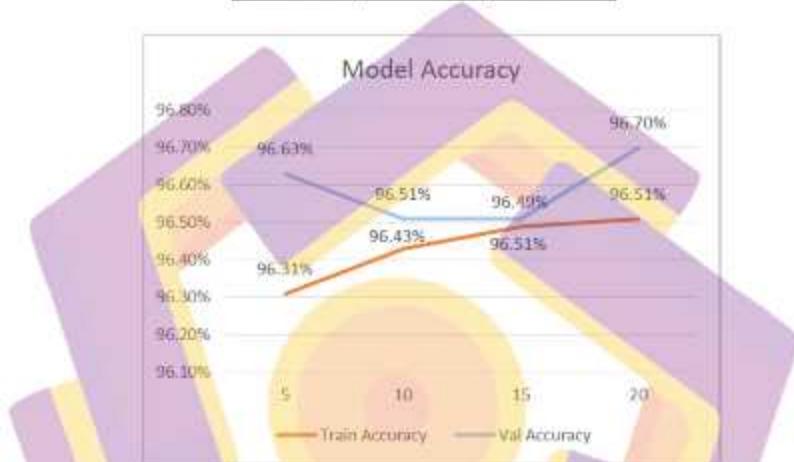
Epoch	Train Loss	Validation Loss	Train Accuracy	Val Accuracy	Time
5	0.0324	0.1427	98.86%	97.83%	12m 16s
10	0.0310	0.1427	98.95%	97.83%	24m 29s
15	0.0294	0.1427	99.01%	97.83%	36m 29s
20	0.0396	0.1427	98.89%	97.83%	49m 53ss

Berdasarkan hasil pengujian diatas diperoleh bahwa akurasi tertinggi adalah pada scenario epoch 15 dengan akurasi validasi mencapai 97.83% dengan validation loss 0.1427 dan train akurasi tertinggi mencapai 99.01. Confusion matriks untuk data testing dengan akurasi 97.83% dapat dilihat pada Tabel 4.4 dan

grafik model accuracy dan model loss training dapat dilihat pada Gambar 12 & Gambar 13.

Tabel 4.5. Confusion Matrix data testing untuk klasifikasi 2 kelas menggunakan SqueezeNet 1.1

	TRUE	FALSE
TRUE	792	7
FALSE	11	21



Gambar 4.10. Grafik Model Training Accuracy SqueezeNet Klasifikasi 2 kelas



Gambar 4.11. Grafik Model Training Loss SqueezeNet 1.1 Klasifikasi 2 kelas

4.4. Skenario Pengujian Klasifikasi 4 Kelas

Pada skenario ini akan diujikan klasifikasi pada 4 kelas data yaitu Empty Bottle, Label Bottle, Empty Can dan Label Can menggunakan algoritma Resnet50 dan SqueezeNet 1.1. Pembagian porsi data training dan data testing dibagi menjadi 80% data training dan 20% data testing. Skenario epoch akan dibagi dalam 4 skenario yaitu 5, 10, 15, dan 20.

4.4.1. Pengujian & Evaluasi Klasifikasi 4 Kelas menggunakan ResNet 50

Berikut adalah hasil dari pengujian model menggunakan algoritma resnet50 untuk melakukan klasifikasi terhadap 4 kelas data dengan 4 skenario epoch yang berbeda-beda.

Pada Tabel 4.5 dapat dilihat bahwa akurasi terbaik saat validasi diperoleh saat scenario epoch 20 dengan akurasi sebesar 91.23% dan loss 0.27061.

Tabel 4.6. Hasil Evaluasi pengujian klasifikasi 4 kelas menggunakan Resnet50

Epoch	Train Loss	Validation Loss	Train Accuracy	Val Accuracy	Time
5	0.15821	0.30390	93.30%	88.34%	8m 43s
10	0.12981	0.32046	94.64%	88.29%	16m 5s
15	0.10580	0.31010	95.66%	87.84%	16m 21s
20	0.12629	0.27061	94.71%	91.23%	21m 49s

Hasil pengujian menggunakan data testing didapatkan akurasi sebesar 84.8% dengan akurasi tiap kelas sebagai berikut.

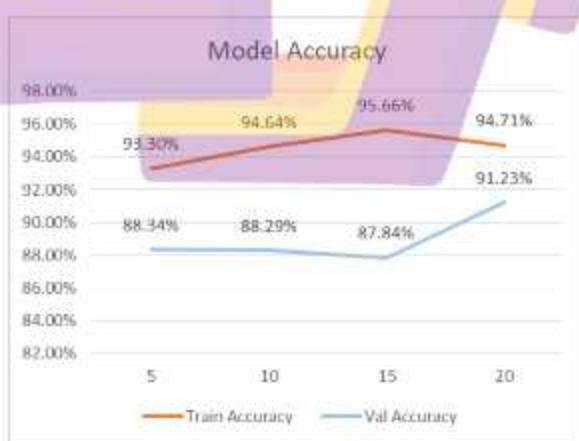
Tabel 4.7. Akurasi data testing tiap Label kelas

Label	% Akurasi
Label Bottle	83.5%
Empty Bottle	97.1%
Label Can	60%
Empty Can	100%

Berikut confusion matriks untuk pengujian dengan akurasi tertinggi dan grafik untuk model accuracy dan model loss.

Tabel 4.8. Confusion Matrix dengan akurasi tertinggi untuk klasifikasi 4 kelas menggunakan Resnet50

	Label Bottle	Empty Bottle	Label Can	Empty Can
Label Bottle	642	37	1	0
Empty Bottle	9	110	0	0
Label Can	9	0	15	0
Empty Can	0	0	0	11



Gambar 4.12. Grafik Model Accuracy Resnet50 Klasifikasi 4 kelas



Gambar 4.13. Grafik Model Loss Resnet50 Klasifikasi 4 kelas

4.4.2. Pengujian & Evaluasi Klasifikasi 4 Kelas menggunakan SqueezeNet 1.1

Berikut adalah hasil dari pengujian model menggunakan algoritma squeezeenet 1.1 untuk melakukan klasifikasi terhadap 4 kelas data dengan 4 skenario epoch yang berbeda-beda.

Tabel 4.9. Hasil Evaluasi pengujian klasifikasi 4 kelas menggunakan SqueezeNet 1.1

Epoch	Train Loss	Validation Loss	Train Accuracy	Val Accuracy	Time
5	0.08805	0.25077	96.53%	88.34%	21m 40s
10	0.11235	0.24132	95.46%	88.97%	49m 27s
15	0.09042	0.25077	96.32%	88.34%	65m 24s
20	0.08730	0.18995	96.32%	91.18%	90m 25s

Berdasarkan pengujian yang dilakukan, diperoleh data bahwa akurasi tertinggi saat training dimiliki pada scenario 20 epoch dengan nilai 91.18% dan loss sebesar 0.18995. Untuk hasil pengujian menggunakan data testing didapatkan akurasi 90.7% dengan akurasi tiap kelas dapat dilihat pada Tabel 4.9.

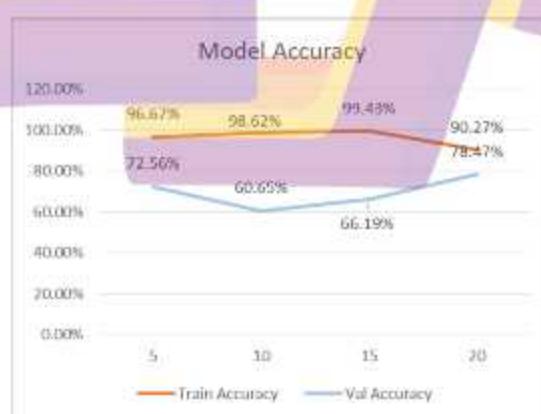
Tabel 4.10. Akurasi data testing untuk tiap Label kelas

Label	% Akurasi
Label Bottle	92.8%
Empty Bottle	78.4%
Label Can	80.2%
Empty Can	100%

Berikut merupakan tabel confusion matriks untuk akurasi testing 4 kelas.

Tabel 4.11. Confusion Matrix dengan akurasi tertinggi untuk klasifikasi 4 kelas menggunakan SqueezeNet 1.1

	Label Bottle	Empty Bottle	Label Can	Empty Can
Label Bottle	631	49	0	0
Empty Bottle	13	103	3	0
Label Can	0	4	13	4
Empty Can	0	0	0	11



Gambar 4.14. Grafik Model Accuracy SqueezeNet Klasifikasi 4 kelas



Gambar 4.15. Grafik Model Loss SqueezeNet Klasifikasi 4 kelas

4.5. Analisis Hasil

Berdasarkan hasil pengujian menggunakan 2 jumlah kelas yang berbeda untuk mendapatkan model dan akurasi terbaik dalam klasifikasi sampah botol plastic dan kaleng dapat disimpulkan sebagai berikut:

1. Model terbaik untuk klasifikasi 2 kelas (Bottle, Can) berdasarkan akurasi dicapai oleh SqueezeNet 1.1 dengan hasil 96.13%.
2. Model terbaik untuk klasifikasi 4 kelas (Label Bottle, Empty Bottle, Label Can & Empty Can) dimiliki oleh SqueezeNet 1.1 dengan akurasi 90.7%.
3. Pada klasifikasi 4 kelas (Label Bottle, Empty Bottle, Label Can & Empty Can), hasil akurasi untuk tiap model yang diuji menghasilkan akurasi yang berbeda dalam tiap kelas. Dari Tabel dibawah dapat dilihat untuk kelas Empty Can menghasilkan akurasi sempurna sedangkan untuk Label Can akurasi cenderung rendah untuk kedua model.

Tabel 4.12. Hasil pengujian algoritma SqueezeNet 1.1

Label	% Akurasi
Label Bottle	92.8%
Empty Bottle	78.4%
Label Can	80.2%
Empty Can	100%

Tabel 4.13. Hasil pengujian algoritma Resnet 50

Label	% Akurasi
Label Bottle	83.5%
Empty Bottle	97.1%
Label Can	60%
Empty Can	100%

Dari Tabel diatas dapat dilihat untuk kelas Empty Can menghasilkan akurasi sempurna sedangkan untuk Label Can akurasi cenderung rendah untuk kedua model. Hal ini dapat terjadi data yang digunakan memiliki banyak persamaan secara visual sehingga saat model membaca dan melakukan klasifikasi, model mendekripsi kelas yang salah. Salah satu contoh data yang kemungkinan prediksi kelas Label Can rendah untuk kedua model dibanding prediksi kelas yang lain terlihat pada gambar dibawah. Dapat dilihat untuk 4 gambar di bawah, sebelah kiri merupakan gambar di kelas Label Can dan sebelah kanan kelas Label Bottle. Ke empat gambar merupakan botol minuman dari brand yang sama sehingga warna dan logo yang digunakan sama, hal inilah yang

menyebabkan model menghasilkan akurasi yang rendah untuk Label Can. Jumlah dataset untuk Label Can yang sedikit berbanding terbalik dengan jumlah dataset untuk Label Bottle yang banyak mempengaruhi hasil prediksi.



Gambar 4.16 Data Botol Plastik 1500ml & Kaleng

Sedangkan untuk Empty Can hasil prediksi yang sempurna dapat disebabkan karena warna dan bentuk yang berbeda dibanding kelas lainnya. Dapat dilihat pada gambar dibawah, Empty Can memiliki warna yang sangat berbeda dibanding gambar di kelas lain sehingga model mendeksnnya dengan mudah.



Gambar 4.17 Data Botol Plastik & Kaleng

4. Jika dilihat dari hasil pengujian kedua algoritma sebelumnya, dapat disimpulkan bahwa SqueezeNet 1.1 menghasilkan akurasi dan performa terbaik untuk semua scenario kelas.
5. Hasil yang diperoleh pada penelitian ini lebih baik dari penelitian sebelumnya dimana pada 2 penelitian sebelumnya menghasilkan akurasi sebesar 95% dan 85.3% untuk klasifikasi Botol Plastik dan Kaleng.

BAB V

PENUTUP

5.1. Kesimpulan

Berdasarkan dari hasil penelitian yang telah dilakukan maka disimpulkan bahwa :

- a. Algoritma terbaik untuk klasifikasi bottle dan can yang diusulkan pada penelitian dari segi akurasi model adalah SqueezeNet 1.1 dengan akurasi 96.13% untuk klasifikasi 2 kelas dan 90.7% pada klasifikasi 4 kelas.
- b. Klasifikasi pada 2 kelas yaitu bottle dan can memiliki akurasi lebih besar untuk kedua model dibandingkan akurasi pada klasifikasi 4 kelas (Empty bottle, Label bottle, Empty Can dan Label Can).

5.2. Saran

Adapun saran untuk meningkatkan atau pengembangan penelitian ini yaitu:

- a. Menggunakan dataset yang lebih banyak terutama untuk data botol kaleng minuman yang pada penelitian ini jumlahnya terbatas.
- b. Menggunakan algoritma klasifikasi yang terbaru untuk meningkatkan akurasi maupun performa pada penelitian.

DAFTAR PUSTAKA

PUSTAKA MAJALAH, JURNAL ILMIAH ATAU PROSIDING

- Andreopoulos, A., & Tsotsos, J. K. (2013). 50 Years of object recognition: Directions forward. *Computer Vision and Image Understanding*. <https://doi.org/10.1016/j.cviu.2013.04.005>
- Awaludin, I., Fadhil, M., Andhika Zaini Zulfikor, M., Negeri Bandung Jl Gegerkalong Hilir, P., Parongpong, K., Bandung Barat, K., Barat, J., & Artikel, I. (2022). Analisis Kinerja ResNet-50 dalam Klasifikasi Penyakit pada Daun Kopi Robusta. *JURNAL INFORMATIKA*, 9(2). <http://ejournal.bsi.ac.id/ejurnal/index.php/ji>
- Dhulekar, P., Gandhe, S. T., & Mahajan, U. P. (2018). Development of Bottle Recycling Machine Using Machine Learning Algorithm. *2018 International Conference On Advances in Communication and Computing Technology, ICACCT 2018*. <https://doi.org/10.1109/ICACCT.2018.8529483>
- Ejiri, M. (2007). Machine vision in early days: Japan's pioneering contributions. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. https://doi.org/10.1007/978-3-540-76386-4_3
- Jambeck, J. R., Geyer, R., Wilcox, C., Siegler, T. R., Perryman, M., Andrady, A., Narayan, R., & Law, K. L. (2015). Plastic waste inputs from land into the ocean. *Science*, 347(6223), 768–771. <https://doi.org/10.1126/science.1260352>

- Karuniastuti, N. (n.d.). *BAHAYA PLASTIK TERHADAP KESEHATAN DAN LINGKUNGAN* (Vol. 03, Issue 1).
- Kashioka, S., Ejiri, M., & Sakamoto, Y. (1976). A Transistor Wire-Bonding System Utilizing Multiple Local Pattern Matching Techniques. *IEEE Transactions on Systems, Man and Cybernetics*. <https://doi.org/10.1109/TSMC.1976.4309551>
- Kokoulin, A. N., & Kiryanov, D. A. (n.d.). *The Optical Subsystem for the Empty Containers Recognition and Sorting in a Reverse Vending Machine*.
- Korucu, M. K., Kaplan, Ö., Büyükk, O., & Güllü, M. K. (2016). An investigation of the usability of sound recognition for source separation of packaging wastes in reverse vending machines. *Waste Management*, 36, 46–52. <https://doi.org/10.1016/j.wasman.2016.06.030>
- Lemieux, P. M., Lutes, C. C., Abbott, J. A., & Aldous, K. M. (2000). Emissions of polychlorinated dibenzo-p-dioxins and polychlorinated dibenzofurans from the open burning of household waste in barrels. *Environmental Science and Technology*, 34(3), 377–384. <https://doi.org/10.1021/es990465t>
- Lin, K., Zhao, Y., Wang, L., Shi, W., Cui, F., & Zhou, T. (2023). MSWNet: A visual deep machine learning method adopting transfer learning based upon ResNet 50 for municipal solid waste sorting. *Frontiers of Environmental Science and Engineering*, 17(6). <https://doi.org/10.1007/s11783-023-1677-1>
- Mariya, D., Usman, J., Mathew, N., Ph, H., Azeez, A., Balakrishnan, U., Marut, V., Godki, H., & Chandrasek..., K. (n.d.). Reverse Vending Machine for Plastic Bottle Recycling. *International Journal of Computer Science Trends and Technology (IJCST)*, 8. www.ijcstjournal.org

- Mittal, G., Yagnik, K. B., Garg, M., & Krishnan, N. C. (2016). SpotGarbage: Smartphone app to detect garbage using deep learning. *UbiComp 2016 - Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, 940–945. <https://doi.org/10.1145/2971648.2971731>
- Parmonangan R, Togotorop, & Ahmad Fauzi. (2022). Klasifikasi Penggunaan Masker Wajah Menggunakan SqueezeNet. *Jurnal Teknik Informatika Dan Sistem Informasi*, Vol. 9.
- Ruiz, V., Sánchez, Á., Vélez, J. F., & Raducanu, B. (2019). Automatic Image-Based Waste Classification. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 11487 LNCS, 422–431. https://doi.org/10.1007/978-3-030-19651-6_41
- Rzechowski, K. (n.d.). *Automated Waste Classification on Embedded Platforms*. <https://www.researchgate.net/publication/366986631>
- S. Sudha, M.Vidhyalakshmi, & K.Pavithra. (n.d.). *AN AUTOMATIC CLASSIFICATION METHOD FOR ENVIRONMENT* (TIAR, 2016).
- Sakr, G. E., Mokbel, M., Darwich, A., Khneisser, M. N., & Hadi, A. (2016). Comparing deep learning and support vector machines for autonomous waste sorting. *2016 IEEE International Multidisciplinary Conference on Engineering Technology*, IMCET 2016. <https://doi.org/10.1109/IMCET.2016.7777453>

- S.K., P., S.V., M., Mhatre, P., S, A. G., R, D., & U, S. (2019). *A Study on Challenges for Adoption of Reverse Vending Machine: A Case of North Bengaluru, India.* 15–29. <https://doi.org/10.17501/26510251.2019.1202>
- Tomari, R., Kadir, A. A., Zakaria, W. N. W., Zakaria, M. F., Wahab, M. H. A., & Jabbar, M. H. (2017). Development of Reverse Vending Machine (RVM) Framework for Implementation to a Standard Recycle Bin. *Procedia Computer Science*, 105, 75–80. <https://doi.org/10.1016/j.procs.2017.01.202>
- Tur, A. I., Kokoulin, A. N., Yuzhakov, A. A., Polygalov, S. V., Troegubov, A. S., & Korotaev, V. N. (2019). Beverage Container Collecting Machine Project. *IOP Conference Series: Earth and Environmental Science*, 317(1). <https://doi.org/10.1088/1755-1315/317/1/012006>
- Wachs Lopes, G. A., IEEE Robotics and Automation Society. South Brazil Chapter, Centro Universitário da FEI, Sociedade Brasileira de Computação., IEEE Computer Society, & Institute of Electrical and Electronics Engineers. (n.d.). *XV Workshop of Computer Vision : WVC 2019 : proceedings : São Bernardo do Campo, São Paulo, Brazil, 09 - 11, September 2019.*
- Wahyudin, G. D., & Afriansyah, A. (2020). Penanggulangan Pencemaran Sampah Plastik Di Laut Berdasarkan Hukum Internasional. *Jurnal IUS Kajian Hukum Dan Keadilan*, 8(3), 529. <https://doi.org/10.29303/ius.v8i3.773>
- Yang, M., & Thung, G. (n.d.). *Classification of Trash for Recyclability Status.*
- Yoo, J., Sohn, Y., Bae, Y., & Kang, B. (2022). *Clean Bottle: A Reverse Vending Machine that Detects Clean PET Bottles with Machine Learning.* 137–142. <https://doi.org/10.12792/iciae2022.025>

- Yoo, T., Lee, S., & Kim, T. (2021). Dual image-based cnn ensemble model for waste classification in reverse vending machine. *Applied Sciences (Switzerland)*, 11(22). <https://doi.org/10.3390/app112211051>
- Zia, H., Jawaid, M. U., Fatima, H. S., Hassan, I. U., Hussain, A., Shahzad, S., & Khurram, M. (2022). Plastic Waste Management through the Development of a Low Cost and Light Weight Deep Learning Based Reverse Vending Machine. *Recycling*, 7(5), 70. <https://doi.org/10.3390/recycling7050070>



LAMPIRAN

