



GARBAGE CLASSIFICATION

LAPORAN KERJA PRAKTIK



NAUFAL DZAKY SYAHRAFI

21410200012

UNIVERSITAS
Dinamika

FAKULTAS TEKNOLOGI DAN INFORMATIKA

UNIVERSITAS DINAMIKA

2024

GARBAGE CLASSIFICATION

Diajukan sebagai salah satu syarat untuk menyelesaikan

Mata Kuliah Kerja Praktik

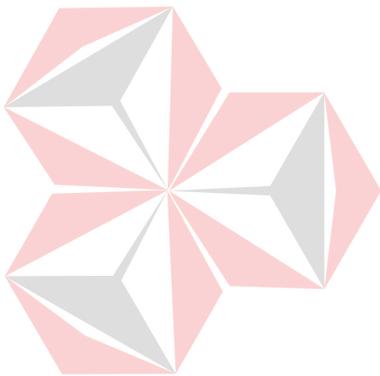
Disusun Oleh :

Nama : NAUFAL DZAKY SYAHRAFI

NIM : 21410200012

Program : S1 (Strata Satu)

Jurusan : Teknik Komputer



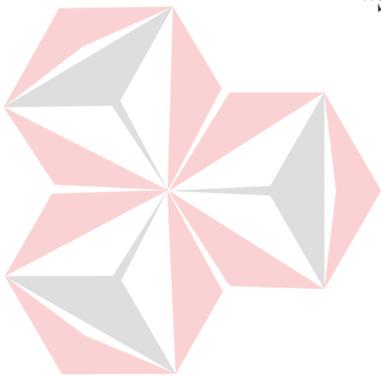
FAKULTAS TEKNOLOGI DAN INFORMATIKA

UNIVERSITAS DINAMIKA

2024

“Sesungguhnya bersama kesulitan ada kemudahan”

(Al – Insyirah ayat 6)



UNIVERSITAS
Dinamika

LEMBAR PENGESAHAN
GARBAGE CLASSIFICATION

Laporan Kerja Praktik oleh

Naufal Dzaky Syahrafi

NIM: 21410200012

Telah diperiksa, diuji, dan disetujui

Surabaya, 31 Juli 2024



Pembimbing

cn=Harianto Harianto,
o=Universitas Dinamika,
ou=Prodi S1 Teknik Komputer,
email=har@dinamika.ac.id,
c-ID
2024.07.31 19:24:47 +0700'

Harianto, S.Kom., M.Eng.
NIDN. 0722087701

Disetujui:

Penyelia

Lutfi Dwimulya

Mengetahui,

Ketua Program Studi S1 Teknik Komputer

cn=Pauladie Susanto, o=Universitas
Dinamika, ou=PS S1 Teknik
Komputer,
email=pauladie@dinamika.ac.id,
c-ID
2024.07.31 20:50:54 +0700'

Pauladie Susanto, S.Kom., M.T.
NIDN. 0729047501

PERNYATAAN
PERSETUJUAN PUBLIKASI DAN KEASLIAN KARYA ILMIAH

Sebagai mahasiswa Universitas Dinamika, Saya :

Nama : Naufal Dzaky Syahrafi
NIM : 21410200012
Program Studi : SI Teknik Komputer
Fakultas : Fakultas Teknologi dan Informatika
Jenis Karya : Laporan Kerja Praktik
Judul Karya : *GARBAGE CLASSIFICATION*

Menyatakan dengan sesungguhnya bahwa :

1. Demi pengembangan Ilmu Pengetahuan, Teknologi dan Seni, Saya menyetujui memberikan kepada Universitas Dinamika Hak Bebas Royalti Non-Eksklusif (*Non-Exclusive Royalty Free Right*) atas seluruh isi/sebagian karya ilmiah Saya tersebut diatas untuk disimpan, dialihmediakan, dan dikelola dalam bentuk pangkalan data (*database*) untuk selanjutnya didistribusikan atau dipublikasikan demi kepentingan akademis dengan tetap mencantumkan nama Saya sebagai penulis atau pencipta dan sebagai pemilik Hak Cipta.
2. Karya tersebut diatas adalah hasil karya asli Saya, bukan plagiat baik sebagian maupun keseluruhan. Kutipan, karya, atau pendapat orang lain yang ada dalam karya ilmiah ini semata-mata hanya sebagai rujukan yang dicantumkan dalam Daftar Pustaka Saya.
3. Apabila dikemudian hari ditemukan dan terbukti terdapat tindakan plagiasi pada karya ilmiah ini, maka Saya bersedia untuk menerima pencabutan terhadap gelar keserjanaan yang telah diberikan kepada Saya.

Demikian surat pernyataan ini Saya buat dengan sebenar-benarnya.

Surabaya, 25 Juli 2024



Naufal Dzaky Syahrafi
NIM : 21410200012

ABSTRAK

Volume sampah yang terus meningkat menjadi tantangan besar bagi pengelolaan sampah, terutama dalam proses pemilahan yang masih banyak dilakukan secara manual. Pemilahan manual sering kali tidak efisien, memakan waktu, dan berisiko tinggi terhadap kesalahan manusia serta berbahaya bagi kesehatan pekerja. Untuk mengatasi masalah ini, teknologi *Artificial Intelligence* menawarkan solusi yang lebih canggih dan efisien. Proyek ini bertujuan untuk mengembangkan sistem klasifikasi sampah menggunakan model *deep learning*, dengan menggunakan arsitektur ResNet. Sistem ini dirancang untuk mengklasifikasikan sampah kedalam enam kategori, yaitu kertas, plastik, kaca, logam, kardus, dan sampah lain, berdasarkan gambar sampah yang diunggah. Model *deep learning* dilatih menggunakan gambar-gambar dari dataset untuk mengenali dan mengklasifikasikan setiap jenis sampah. Dengan pemanfaatan teknologi ini, diharapkan sistem dapat meningkatkan kecepatan dan akurasi pemilahan sampah, mengurangi ketergantungan pada proses manual, dan berkontribusi pada pengelolaan sampah yang lebih efektif serta pelestarian lingkungan. Hasil pengujian menunjukkan bahwa sistem klasifikasi sampah yang dikembangkan memiliki akurasi yang cukup tinggi dalam mengenali dan mengelompokkan sampah sesuai kategorinya.

Kata Kunci: *Artificial Intelligence*, *Deep Learning*, Klasifikasi Sampah, Pengelolaan Sampah, ResNet

KATA PENGANTAR

Segala puji bagi Allah SWT yang telah memberikan saya kesehatan dan kemudahan sehingga penulis dapat menyelesaikan laporan kerja praktik ini dengan judul “*GARBAGE CLASSIFICATION*” ini dengan baik. Penyelesaian laporan kerja praktik ini sebagai syarat wajib untuk menyelesaikan program sarjana.

Penulis juga ingin menyampaikan rasa terima kasih kepada :

1. Bapak Pauladie Susanto, S.Kom., M.T., selaku Ketua Program Studi S1 Teknik Komputer Universitas Dinamika yang telah memberikan izin kerja praktik.
2. Bapak Harianto, S.Kom., M.Eng. selaku Dosen Pembimbing yang sudah memberikan bantuan selama penyelesaian laporan kerja praktik.
3. Kak Aldo Lionel Saonard selaku Instruktur kelas besar B dan Mentor pengganti.
4. Rekan – rekan saya selama Studi Independen yang telah banyak membantu, memberikan dukungan dan berbagi pengalaman selama program berlangsung.

Surabaya, 31 Juli 2024

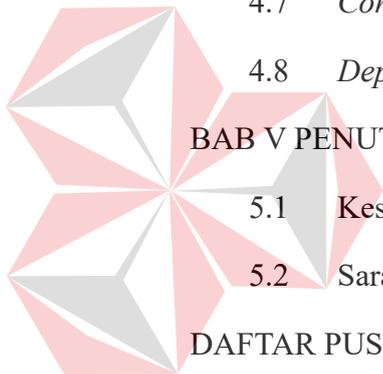


Penulis

DAFTAR ISI

	Halaman
ABSTRAK	v
KATA PENGANTAR.....	vi
DAFTAR ISI	vii
DAFTAR GAMBAR	ix
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah.....	2
1.3 Batasan Masalah	2
1.4 Tujuan	2
1.5 Manfaat	2
BAB II GAMBARAN UMUM.....	3
2.1 Latar Belakang Perusahaan.....	3
2.2 Profil Perusahaan	4
2.3 Visi Perusahaan.....	4
2.4 Misi Perusahaan	4
2.5 Struktur Organisasi	5
BAB III LANDASAN TEORI.....	6
3.1 Pengolahan Sampah dan Kategori Klasifikasi.....	6
3.2 <i>Artificial Intelligence</i>	7
3.3 <i>Computer Vision</i>	8
3.4 <i>Deep Learning</i>	8
3.5 <i>Residual Network (ResNet)</i>	9
3.6 Watsonx.AI.....	10
BAB IV DESKRIPSI PEKERJAAN	12

4.1	Penjelasan Kerja Praktik.....	12
4.2	Lingkup Pekerjaan	12
4.3	Metodologi Penelitian.....	13
4.4	Langkah Pengerjaan.....	13
4.4.1	<i>Data Preparation</i>	13
4.4.2	Pemrosesan Data	16
4.4.3	Arsitektur Model	16
4.4.4	Pelatihan Model.....	17
4.5	Evaluasi Model	18
4.6	Hasil Testing.....	19
4.7	<i>Confusion Matrix</i>	21
4.8	<i>Deployment</i>	21
BAB V PENUTUP.....		23
5.1	Kesimpulan	23
5.2	Saran	23
DAFTAR PUSTAKA		24



DAFTAR GAMBAR

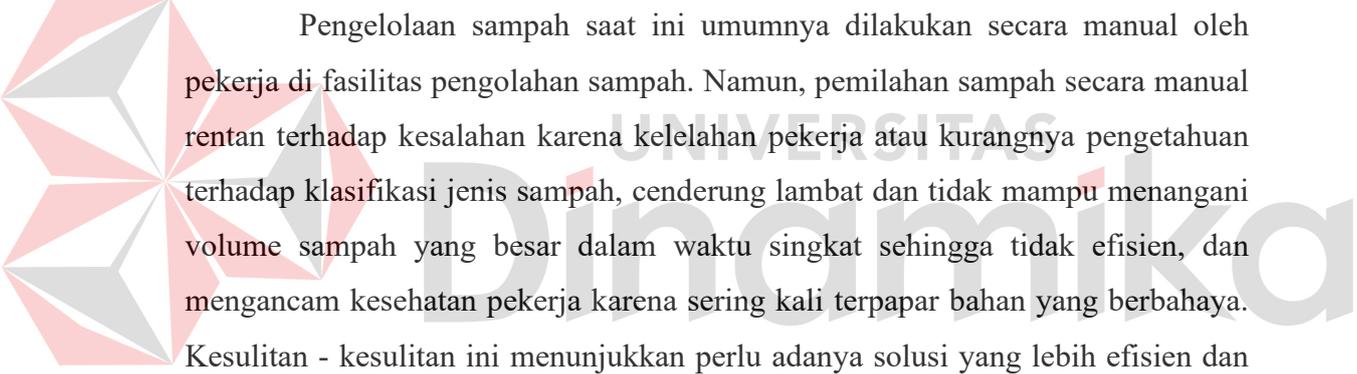
	Halaman
Gambar 2.1 Logo Hacktiv8.....	3
Gambar 2.2 Struktur Organisasi Hacktiv8	5
Gambar 4.1 Sumber Dataset	13
Gambar 4.2 Show image of dataset.....	14
Gambar 4.3 Kardus	14
Gambar 4.4 Kaca.....	14
Gambar 4.5 Kertas	15
Gambar 4.6 Plastik	15
Gambar 4.7 Metal.....	15
Gambar 4.8 Sampah lain	15
Gambar 4.9 Contoh Image data generator	16
Gambar 4.10 Arsitektur model.....	17
Gambar 4.11 Pelatihan Model.....	18
Gambar 4.12 Classification Report.....	19
Gambar 4.13 Hasil Testing.....	20
Gambar 4.14 Hasil Testing 2.....	20
Gambar 4.15 Confusion Matrix	21
Gambar 4.16 Hasil deployment.....	22
Gambar 4.17 Hasil deployment 2.....	22

BAB I

PENDAHULUAN

1.1 Latar Belakang

Dalam beberapa tahun ini, volume sampah yang dihasilkan oleh manusia meningkat seiring dengan pertumbuhan populasi dan industrial. Pengelolaan sampah yang tidak efektif dapat menimbulkan berbagai masalah lingkungan seperti pencemaran tanah, air, dan udara. Salah satu langkah dalam pengelolaan sampah yang lebih baik adalah dengan proses pemilahan sampah. Pemilahan sampah bertujuan untuk memisahkan sampah berdasarkan jenis materialnya, sehingga memungkinkan adanya daur ulang dan pengelolaan yang lebih efisien.



Pengelolaan sampah saat ini umumnya dilakukan secara manual oleh pekerja di fasilitas pengolahan sampah. Namun, pemilahan sampah secara manual rentan terhadap kesalahan karena kelelahan pekerja atau kurangnya pengetahuan terhadap klasifikasi jenis sampah, cenderung lambat dan tidak mampu menangani volume sampah yang besar dalam waktu singkat sehingga tidak efisien, dan mengancam kesehatan pekerja karena sering kali terpapar bahan yang berbahaya. Kesulitan - kesulitan ini menunjukkan perlu adanya solusi yang lebih efisien dan aman. Teknologi *Artificial Intelligence*, seperti *deep learning*, telah menunjukkan potensi besar dalam berbagai aplikasi, termasuk dalam bidang pengenalan gambar dan klasifikasi objek. Penerapan teknologi ini dalam proses pemilahan sampah dapat meningkatkan akurasi, kecepatan, dan efisiensi proses tersebut.

Proyek "*Garbage Classification*" ini bertujuan untuk mengembangkan sistem yang mampu mengklasifikasikan sampah ke dalam beberapa kategori dengan menggunakan model *deep learning*, khususnya arsitektur ResNet. Dengan adanya sistem ini, diharapkan dapat membantu memecahkan masalah yang dihadapi dalam proses pemilahan sampah manual, mengurangi beban kerja manusia, dan meningkatkan efektivitas pengelolaan sampah.

1.2 Rumusan Masalah

Bagaimana mengembangkan sistem klasifikasi sampah menggunakan model *deep learning* untuk meningkatkan efisiensi dan akurasi pemilahan sampah?

1.3 Batasan Masalah

Berdasarkan uraian di atas, maka dalam pelaksanaan Kerja Praktik terdapat beberapa batasan masalah, antara lain :

1. Proyek ini hanya mengklasifikasikan sampah ke dalam enam kategori.
2. Terbatas pada penggunaan arsitektur *deep learning* ResNet.
3. Dataset yang digunakan terbatas pada gambar sampah yang tersedia secara publik.
4. Evaluasi dilakukan berdasarkan metrik akurasi, presisi, dan recall dalam klasifikasi gambar.

1.4 Tujuan

Proyek ini bertujuan untuk mengklasifikasikan sampah ke dalam berbagai kategori menggunakan model *deep learning*. Dengan memanfaatkan teknologi ini, diharapkan kita dapat meningkatkan efisiensi dan akurasi dalam pemilahan sampah.

1.5 Manfaat

Adapun manfaat dari pelaksanaan kerja praktik ini antara lain sebagai berikut :

1. Pelestarian Lingkungan, yaitu mengurangi pencemaran tanah dan air dengan memisahkan bahan berbahaya dari sampah organik serta mempermudah daur ulang material yang dapat digunakan kembali sehingga mengurangi penggunaan sumber daya alam.
2. Manajemen limbah, yaitu meningkatkan efisiensi dalam proses pengelolaan dan pembuangan sampah, serta memfasilitasi pengolahan limbah yang lebih efektif sehingga mengurangi volume sampah yang masuk ke Tempat Pembuangan Akhir.

BAB II

GAMBARAN UMUM

2.1 Latar Belakang Perusahaan

Hacktiv8 adalah program reskilling yang mendalam (bootcamp) yang mengubah pemula menjadi talenta digital siap kerja. Sejak tahun 2016, Hacktiv8 telah berdedikasi mengatasi kesenjangan keterampilan teknologi melalui kurikulum komprehensif dan praktis yang mempersiapkan siswa untuk sukses berkarir serta berkontribusi pada pertumbuhan ekonomi Indonesia. Dengan 7.200+ siswa terlatih, hacktiv8 mendorong transformasi digital dan pembekalan individu di industri teknologi yang dinamis. Hacktiv8 dimulai pada Maret 2016. Riza dan Ronald memulai untuk melatih *developers* untuk mencapai standar yang bisa mereka pekerjaan dan dimasukkan ke dalam proyek dalam waktu yang singkat. Apa yang dimulai sebagai proyek sampingan dengan cepat menjadi sebuah perusahaan sebagai masalah yang ingin dipecahkan menjadi sebuah bisnis. Segera, Hacktiv8 yang sebelumnya hanya sebuah proyek sampingan dimasukkan ke dalam perusahaan untuk memecahkan kebutuhan perekrutan banyak perusahaan berbeda yang membutuhkan *digital skills*.



Gambar 2.1 Logo Hacktiv8

2.2 Profil Perusahaan

Nama Instansi : PT Hacktivate Teknologi Indonesia

Alamat : Gedung Aquarius Lt. 1&2, Jl. Sultan Iskandar Muda No. 7,
RT. 005 RW. 009, Kebayoran Lama Selatan, Kebayoran
Lama, Jakarta Selatan 12240

No. Telepon : (021) 8067 5787

Website : <https://www.haktiv8.com/>

Email : halo@haktiv8.com

2.3 Visi Perusahaan

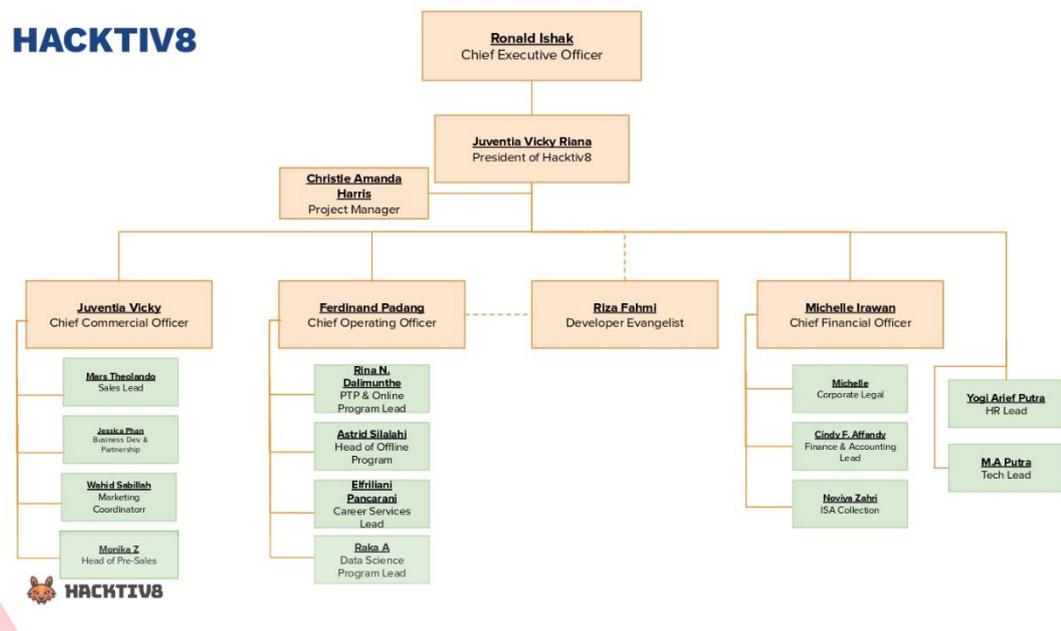
Haktiv8 memiliki visi meningkatkan kualitas hidup individu melalui pendidikan teknologi dan memberdayakan mereka untuk memulai karir yang sukses di industri teknologi.

2.4 Misi Perusahaan

Menyediakan pendidikan berkualitas tinggi dan pelatihan intensif dalam bidang pemrograman dan teknologi, serta mendukung lulusan dalam mendapatkan pekerjaan di perusahaan-perusahaan terkemuka.

2.5 Struktur Organisasi

Berikut struktur organisasi PT Hacktivate Teknologi Indonesia :



Gambar 2.2 Struktur Organisasi Hacktiv8



BAB III

LANDASAN TEORI

3.1 Pengolahan Sampah dan Kategori Klasifikasi

Pengolahan sampah merupakan serangkaian proses yang bertujuan untuk mengelola limbah dari sumber hingga pembuangan akhir. Salah satu tahap penting dalam pengolahan sampah adalah pemilahan, yang memisahkan sampah berdasarkan jenis materialnya untuk memungkinkan proses daur ulang dan pengelolaan yang lebih efisien. Dalam proyek “*Garbage Classification*” ini, sampah diklasifikasikan ke dalam enam kategori, yaitu :

1. Kertas :

Kategori ini meliputi produk-produk seperti koran, majalah, kardus, dan kertas tulis. Kertas adalah salah satu bahan yang paling mudah didaur ulang, karena dapat dihancurkan dan dibentuk kembali menjadi produk kertas baru. Proses daur ulang kertas melibatkan pemisahan dari kontaminan, penghancuran, dan pembentukan kembali (Pongrácz, 2002).

2. Plastik :

Plastik adalah salah satu jenis limbah yang paling banyak dihasilkan dan memiliki berbagai variasi, seperti PET, HDPE, PVC, dan lainnya. Plastik membutuhkan waktu yang sangat lama untuk terurai secara alami, sehingga daur ulang plastik sangat penting. Proses ini melibatkan pemisahan berdasarkan jenis resin, pencucian, penghancuran, dan peleburan menjadi produk baru (Hopewell, Dvorak, & Kosior, 2009)

3. Kaca :

Limbah kaca meliputi botol, gelas, dan berbagai produk kaca lainnya. Kaca dapat didaur ulang tanpa batas tanpa kehilangan kualitasnya. Proses daur ulang kaca melibatkan pemisahan berdasarkan warna, penghancuran menjadi pecahan kecil, dan peleburan kembali untuk membentuk produk baru (Cimpan, Maul, Jansen, Pretz, & Wenzel, 2015)

4. Logam :

Kategori logam mencakup berbagai jenis logam seperti aluminium, baja, dan besi. Logam dapat didaur ulang dengan tingkat efisiensi tinggi karena dapat dilebur dan digunakan kembali. Pengolahan logam biasanya melibatkan pemisahan berdasarkan jenis logam, pencucian, penghancuran, dan peleburan (Morris, 2005)

5. Kardus :

Kardus termasuk dalam kategori kertas, namun sering dipisahkan karena biasanya terbuat dari material yang lebih tebal dan kuat. Kardus dapat didaur ulang menjadi produk kardus baru atau bahan kertas lainnya. Proses daur ulang kardus mirip dengan kertas lainnya, namun mungkin melibatkan tambahan langkah untuk menghilangkan lapisan pelindung seperti lilin atau plastik (Pongrácz, 2002)

6. Sampah Lain

Kategori ini mencakup berbagai jenis sampah yang tidak termasuk dalam kategori di atas, seperti sisa makanan, bahan tekstil, keramik, dan lainnya. Sampah dalam kategori ini sering kali lebih sulit untuk didaur ulang dan memerlukan penanganan khusus. Sebagian besar sampah ini berakhir di tempat pembuangan akhir (TPA) atau diolah melalui metode seperti komposting atau insinerasi (Kaza, Yao, Bhada-Tata, & Woerden, 2018)

Dengan memahami dan mengklasifikasikan sampah ke dalam kategori-kategori ini, pengelolaan sampah dapat dilakukan dengan lebih efektif. Teknologi seperti *deep learning* dalam sistem klasifikasi sampah dapat mempercepat dan memperbaiki akurasi proses pemilahan ini, mendukung upaya daur ulang, dan mengurangi dampak negatif terhadap lingkungan.

3.2 Artificial Intelligence

Artificial intelligence atau disingkat AI, adalah sebuah teknologi yang memungkinkan komputer dan mesin untuk mensimulasikan kecerdasan manusia dan kemampuan pemecahan masalah. AI dapat bekerja sendiri atau dikombinasikan dengan teknologi lain (misalnya, sensor, geolokasi, robotika) untuk melakukan

tugas yang biasanya memerlukan kecerdasan atau campur tangan manusia. Asisten digital, panduan GPS, kendaraan otonom, dan alat AI generatif (seperti Chat GPT milik Open AI) hanyalah beberapa contoh AI dalam berita harian dan kehidupan kita sehari-hari.

Sebagai bidang ilmu komputer, kecerdasan buatan mencakup *Machine Learning* dan *Deep Learning*. Ilmu ini melibatkan pengembangan algoritma AI, yang dimodelkan berdasarkan proses pengambilan keputusan otak manusia, yang dapat 'belajar' dari data yang tersedia dan membuat klasifikasi atau prediksi yang semakin akurat dari waktu ke waktu.

Artificial Intelligence telah melalui banyak siklus, tetapi bahkan bagi para skeptis, peluncuran ChatGPT tampaknya menandai titik balik. Terakhir kali AI generatif muncul sebesar ini, terobosannya ada di bidang *Computer Vision*, tetapi sekarang ada pada bidang *Natural Language Processing* (NLP). Saat ini, AI generatif dapat mempelajari dan mensintesis tidak hanya bahasa manusia tetapi juga jenis data lain termasuk gambar, video, kode perangkat lunak, dan bahkan struktur molekuler.

3.3 *Computer Vision*

Computer vision adalah bidang ilmu yang berfokus pada pengembangan algoritma dan sistem yang memungkinkan komputer untuk memahami dan menafsirkan informasi dari gambar digital atau video. Teknologi ini memanfaatkan berbagai metode analisis citra, termasuk deteksi tepi, pengenalan pola, dan segmentasi gambar, untuk mengidentifikasi objek, menghitung jarak, atau mengenali aktivitas tertentu dalam suatu gambar atau video. Aplikasi dari *computer vision* sangat luas, mulai dari sistem pengawasan keamanan hingga kendaraan otonom dan diagnostik medis (Gonzalez & Woods, 2018)

3.4 *Deep Learning*

Deep learning adalah salah satu pendekatan dalam *Artificial Intelligence* yang telah merevolusi bidang *computer vision*. Melalui penggunaan jaringan saraf tiruan berlapis-lapis, atau dikenal sebagai *deep neural networks*, *deep learning* memungkinkan komputer untuk belajar mengenali pola yang rumit dalam data

gambar. Salah satu arsitektur *deep learning* yang paling terkenal dan sering digunakan dalam tugas-tugas *computer vision* adalah *Convolutional Neural Network* (CNN). CNN dirancang untuk secara otomatis dan adaptif mempelajari representasi spasial hierarkis dari gambar melalui operasi konvolusi.

Dalam konteks klasifikasi sampah, *deep learning* memungkinkan sistem untuk mempelajari fitur-fitur penting dari berbagai jenis sampah secara otomatis dari dataset gambar yang telah diberi label. Model *deep learning* seperti ResNet (Residual Network) telah terbukti sangat efektif dalam tugas-tugas klasifikasi gambar, termasuk dalam mengidentifikasi dan mengelompokkan jenis sampah berdasarkan ciri-ciri visualnya. Keunggulan utama dari penggunaan *deep learning* dalam *computer vision* adalah kemampuannya untuk menangani dataset yang sangat besar dan kompleks, serta untuk meningkatkan akurasi klasifikasi secara signifikan dibandingkan dengan metode pengolahan gambar tradisional (Krizhevsky, Sutskever, & Hinton, 2012; He, Zhang, Ren, & Sun, 2016)

Penerapan *computer vision* dan *deep learning* dalam sistem klasifikasi sampah tidak hanya mempercepat proses pemilahan, tetapi juga meningkatkan akurasi dengan mengurangi kesalahan yang mungkin terjadi dalam pemilahan manual. Teknologi ini dapat mengenali berbagai material sampah seperti kertas, plastik, kaca, logam, kardus, dan sampah lainnya, yang memungkinkan pengelolaan dan daur ulang sampah yang lebih efisien dan efektif.

3.5 Residual Network (ResNet)

ResNet, atau Residual Network, adalah salah satu arsitektur jaringan saraf tiruan dalam *deep learning* yang secara khusus dirancang untuk mengatasi masalah *vanishing gradient*, yang sering terjadi dalam jaringan saraf yang sangat dalam. Masalah ini dapat menghambat proses pembelajaran jaringan karena gradien yang sangat kecil pada lapisan awal jaringan. ResNet mengatasi masalah ini dengan memperkenalkan *residual blocks*, yang memungkinkan informasi melewati lapisan-lapisan jaringan melalui *shortcut connections*. Hal ini mempermudah proses pelatihan jaringan yang sangat dalam dan memungkinkan model untuk mencapai akurasi yang lebih tinggi.

ResNet pertama kali diperkenalkan oleh Kaiming He dan rekan-rekannya dalam paper mereka yang berjudul "*Deep Residual Learning for Image Recognition*" pada tahun 2015. Mereka menunjukkan bahwa dengan menggunakan arsitektur ini, jaringan dapat mencapai kedalaman yang jauh lebih besar dibandingkan dengan arsitektur tradisional tanpa mengalami penurunan performa. ResNet telah menjadi standar dalam banyak aplikasi *computer vision*, termasuk klasifikasi gambar, deteksi objek, dan segmentasi gambar.

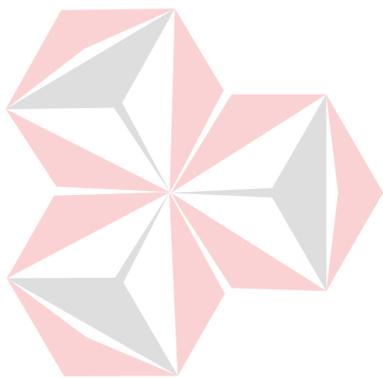
Dalam konteks klasifikasi sampah, ResNet digunakan untuk membedakan antara berbagai jenis sampah berdasarkan fitur visual yang diekstraksi dari gambar. Model ini dapat belajar dari dataset gambar yang luas untuk mengenali pola-pola kompleks yang terkait dengan berbagai kategori sampah, seperti kertas, plastik, kaca, logam, kardus, dan sampah lainnya. Kelebihan utama dari ResNet adalah kemampuannya untuk mempelajari representasi fitur yang sangat dalam dan detail, yang esensial untuk meningkatkan akurasi dalam klasifikasi jenis sampah yang sering kali memiliki penampilan visual yang serupa.

ResNet telah terbukti sangat efektif dalam berbagai kompetisi dan tantangan *computer vision*, menunjukkan keunggulan dalam akurasi klasifikasi dan efisiensi komputasi (He, Zhang, Ren, & Sun, 2016). Implementasi ResNet dalam proyek klasifikasi sampah ini diharapkan dapat memberikan hasil yang akurat dan dapat diandalkan, sehingga mendukung upaya pengelolaan sampah yang lebih efektif dan ramah lingkungan.

3.6 Watsonx.AI

IBM merupakan perusahaan teknologi yang telah lama dikenal dengan kontribusinya dalam bidang komputasi dan kecerdasan buatan. Salah satu inovasi terbaru dari IBM adalah Watsonx.AI, sebuah platform kecerdasan buatan yang menawarkan berbagai layanan dan alat untuk membangun, melatih, dan mengelola model *deep learning*. Watsonx.AI menyediakan infrastruktur yang kuat dan berbagai alat analitik yang memungkinkan pengguna untuk mengembangkan model kecerdasan buatan dengan lebih efisien. Platform ini mendukung berbagai arsitektur *deep learning*, termasuk ResNet, dan dapat digunakan untuk aplikasi seperti klasifikasi gambar, pemrosesan bahasa alami, dan analitik prediktif.

Watsonx.AI dalam proyek klasifikasi sampah ini digunakan untuk melakukan *deployment*.



UNIVERSITAS
Dinamika

BAB IV

DESKRIPSI PEKERJAAN

4.1 Penjelasan Kerja Praktik

Kerja Praktik telah dilakukan sebagai bagian dari kegiatan dalam program Kampus Merdeka Studi Independen Bersertifikat. Pengembangan proyek ini merupakan *Capstone Project* yang wajib dilakukan sebagai syarat untuk kelulusan dalam program Studi Independen. Pengerjaan proyek ini dilakukan secara berkelompok dengan anggota enam orang dengan judul “*Garbage Classification*” yang dimana hasil akhir proyek ini dapat mengklasifikasikan sampah yang terdiri dari enam kategori. Terdapat beberapa kegiatan yang peserta lakukan selama program “*IBM SkillsBuild For AI & Cybersecurity*” di Hacktiv8, antara lain :

1. Pembelajaran Kelas Daring

Pelaksanaan kelas daring dilakukan melalui *Google Meet* dimana peserta dibagi menjadi 2 kelas besar, yaitu kelas A dan kelas B, serta kelas kecil yang dibagi menjadi empat belas kelas mulai dari SI6-01 sampai SI6-14. Kelas besar dilakukan pada hari Senin dan Rabu yang disampaikan oleh masing-masing instruktur, sedangkan kelas kecil melakukan sesi *mentoring* pada hari jum'at, atau sesuai dengan kesepakatan bersama mentor. Materi yang diberikan instruktur dapat diakses melalui laman kode.id.

2. *Self Learning*

Peserta melakukan pembelajaran secara mandiri dengan membaca materi atau menonton video, serta mengerjakan tugas dan kuis mengikuti petunjuk yang tertera pada kode.id. Jadwal *self learning* yang diberikan yaitu pada hari Selasa dan Kamis.

4.2 Lingkup Pekerjaan

Program Magang dan Studi Independen Bersertifikat di PT Hacktivate Teknologi Indonesia, peserta diharuskan memiliki akun kode.id untuk mengakses materi dan perintah tugas yang diberikan. Pembelajaran dilakukan secara *online* melalui *Google Meet* pada hari Senin dan Rabu dengan materi pengembangan *soft*

skills, Python, pengenalan Artificial Intelligence, Machine Learning, Deep Learning, Watsonx.AI dan Cyber Security. Pada kode.id, peserta diarahkan menuju laman *IBM Skillsbuild* dengan kode *redeem* yang telah diberikan untuk masing-masing course dan *Cognitive Class*, kemudian peserta diharuskan mengumpulkan sertifikat setelah menyelesaikan course pada *Google Classroom*.

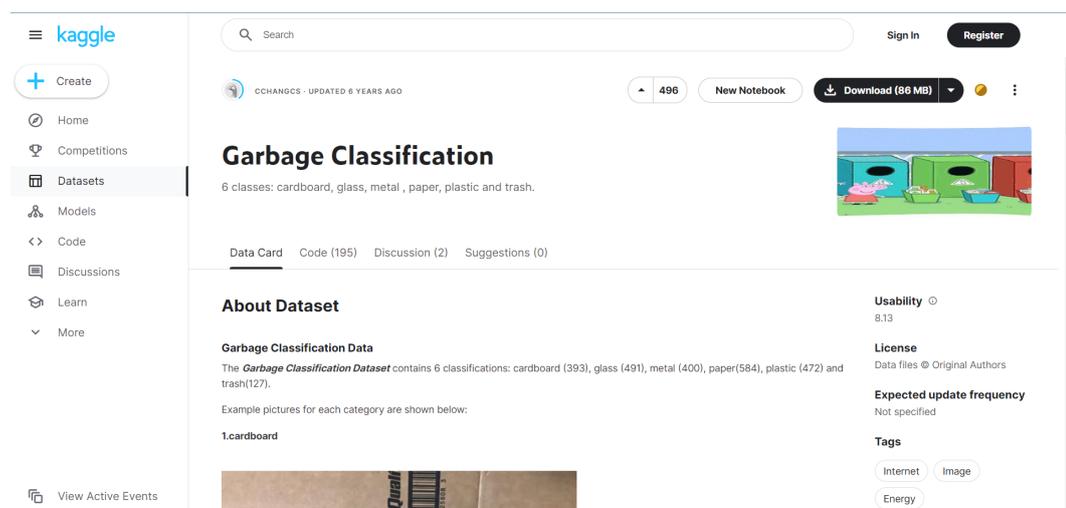
4.3 Metodologi Penelitian

Capstone Project Garbage Classification dilakukan untuk mengklasifikasikan sampah kedalam enam kategori yaitu kertas, plastik, kaca, logam, kardus dan sampah lain dengan menggunakan salah satu bidang dari *Artificial Intelligence* yaitu *Computer Vision*. Tahap akhir dari proyek ini adalah melakukan *deployment* sebagai sarana implementasi model yang telah dibuat dan dilatih.

4.4 Langkah Pengerjaan

4.4.1 Data Preparation

Pada tahap ini, yang pertama dilakukan adalah *download* dataset dari *website Kaggle*, yaitu sebuah platform *online* untuk menyediakan berbagai macam data yang kemudian dapat dipakai dalam proyek *data science* untuk dilakukan analisis dan training data.



Gambar 4.1 Sumber Dataset

(Sumber: <https://www.kaggle.com/datasets/asdasdasdasdas/garbage-classification/data>)

Setelah *download* dataset, tampilkan gambar dari masing-masing kategori yang ada pada dataset.

```

Show images of Dataset

import matplotlib.pyplot as plt
def plot_imgs(item_dir, top=10):
    all_item_dirs = os.listdir(item_dir)
    item_files = [os.path.join(item_dir, file) for file in all_item_dirs][:5]

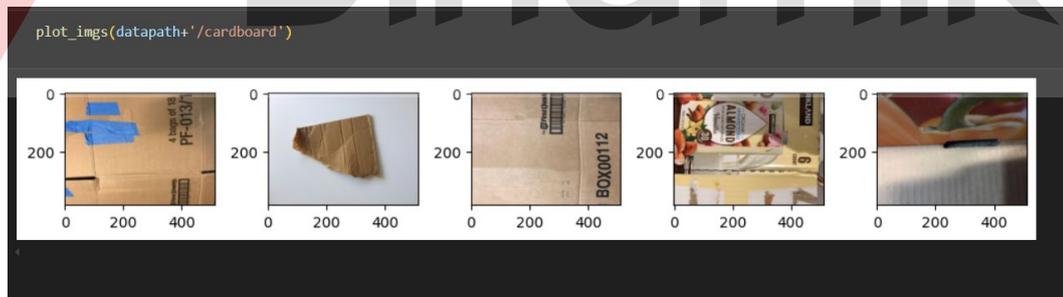
    plt.figure(figsize=(10, 10))

    for idx, img_path in enumerate(item_files):
        plt.subplot(5, 5, idx+1)

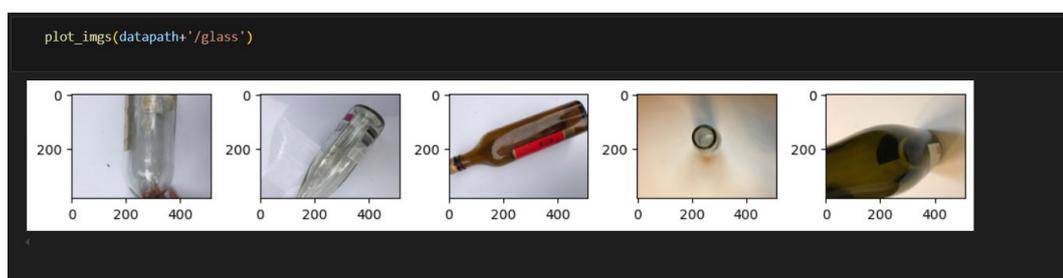
        img = plt.imread(img_path)
        plt.tight_layout()
        plt.imshow(img)

```

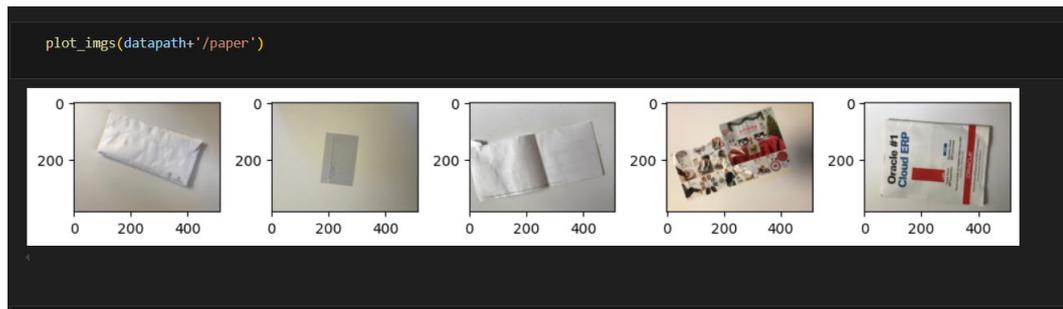
Gambar 4.2 Show image of dataset



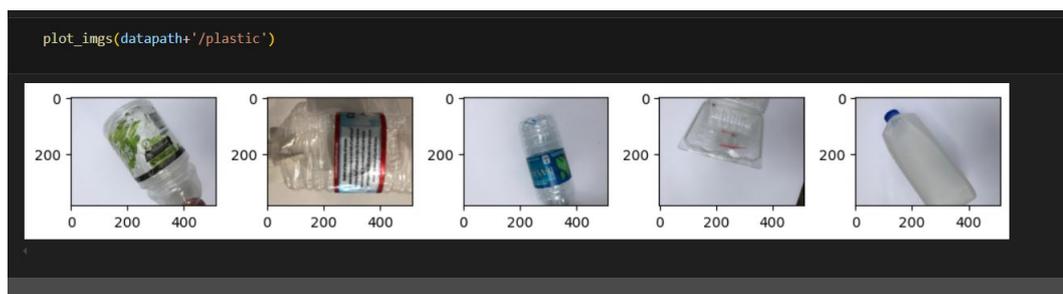
Gambar 4.3 Kardus



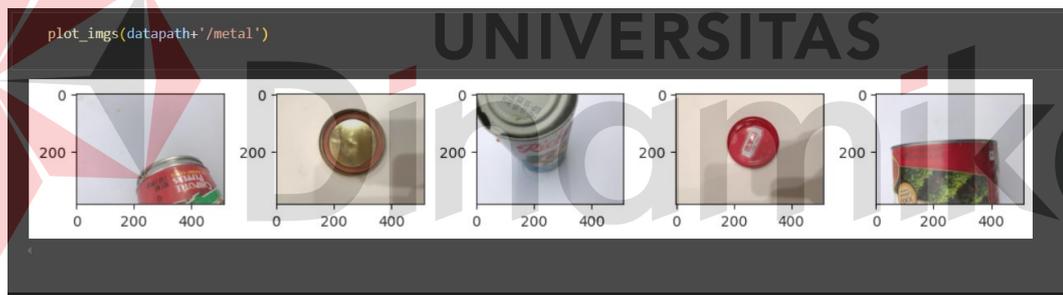
Gambar 4.4 Kaca



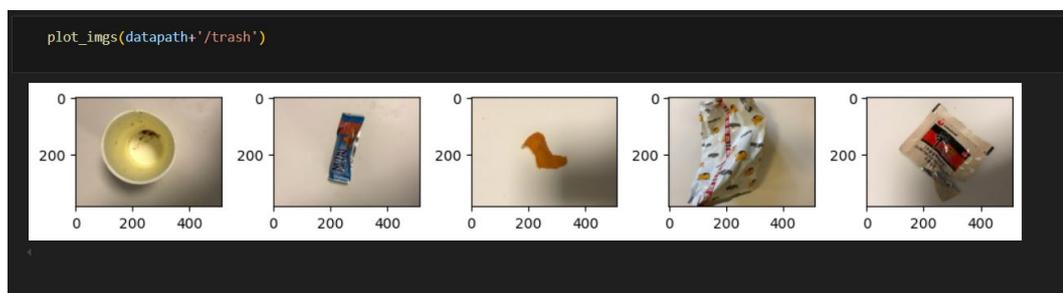
Gambar 4.5 Kertas



Gambar 4.6 Plastik



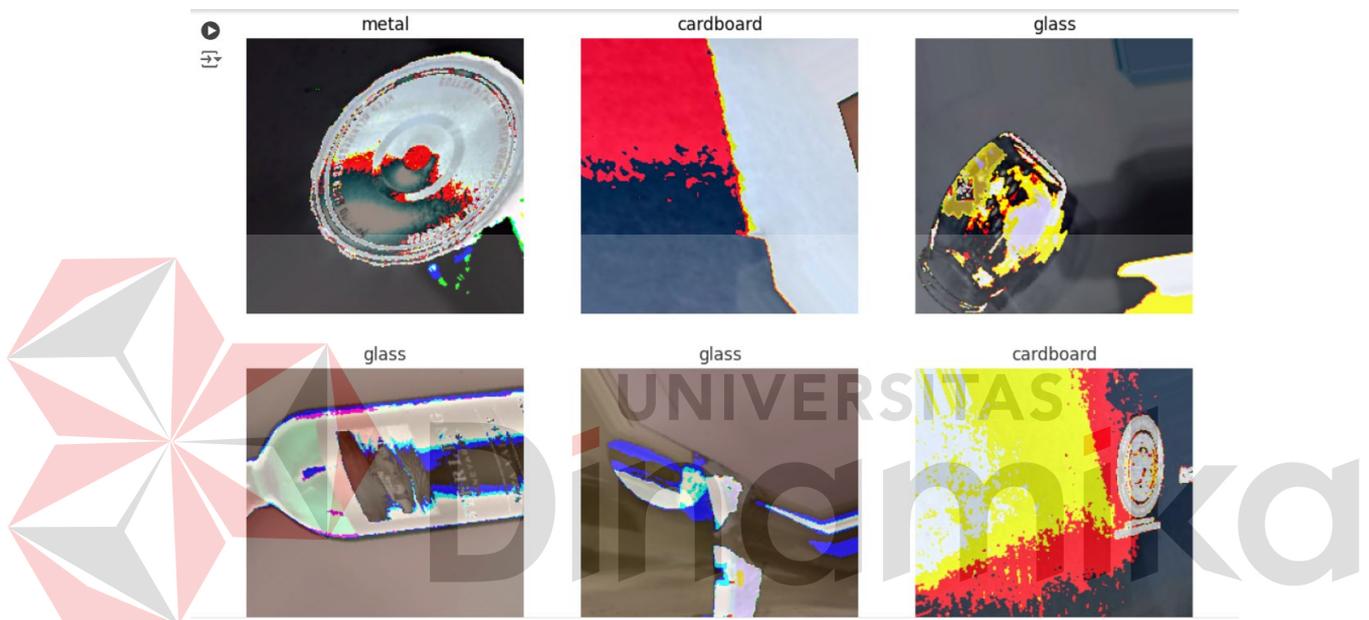
Gambar 4.7 Metal



Gambar 4.8 Sampah lain

4.4.2 Pemrosesan Data

Pemrosesan data dilakukan menggunakan kelas *ImageDataGenerator* dari *TensorFlow* untuk melakukan augmentasi data dari gambar secara *real-time*. *ImageDataGenerator* digunakan untuk augmentasi data gambar dan pembagian data validasi. Proses Augmentasi termasuk rotasi, *flipping*, *zooming* dan pergeseran gambar. *Train_Generator* dan *Test_generator* menghasilkan *batch* gambar dari direktori untuk pelatihan dan validasi. Visualisasi *batch* gambar membantu memeriksa hasil dari augmentasi dan pemrosesan data.



Gambar 4.9 Contoh *Image data generator*

4.4.3 Arsitektur Model

Pada *Capstone Project* ini menggunakan ResNet-152 sebagai basis konvolusi untuk model dari proyek ini. ResNet-152 adalah varian dari ResNet yang lebih dalam dan kompleks dibandingkan dengan ResNet-50 atau ResNet-101. Pemilihan ResNet-152 didasarkan pada kemampuannya untuk menangani tugas klasifikasi gambar yang kompleks dengan baik, terutama saat menggunakan dataset yang lebih besar seperti ImageNet, dan dengan transfer learning dari bobot pra-latih ImageNet, memungkinkan model ini untuk mengambil keuntungan dari arsitektur yang kuat dan fitur-fitur yang relevan yang diekstraksi dari dataset yang luas. Hal

ini memberikan dasar yang solid untuk membangun model klasifikasi yang akurat dan efisien untuk proyek ini.

```
model.compile(optimizer=Adam(learning_rate=0.0001), loss='categorical_crossentropy', metrics=['accuracy'])
```

Downloading data from https://storage.googleapis.com/tensorflow/keras-applications/resnet/resnet152_weights_tf_dim_ordering_tf_kernels_notop.h5
234698864/234698864 [=====] - 2s 0us/step
Model: "sequential"

Layer (type)	Output Shape	Param #
resnet152 (Functional)	(None, 7, 7, 2048)	58370944
global_average_pooling2d (GlobalAveragePooling2D)	(None, 2048)	0
dense (Dense)	(None, 512)	1049088
batch_normalization (Batch Normalization)	(None, 512)	2048
dropout (Dropout)	(None, 512)	0
dense_1 (Dense)	(None, 128)	65664
batch_normalization_1 (Batch Normalization)	(None, 128)	512
dropout_1 (Dropout)	(None, 128)	0
dense_2 (Dense)	(None, 6)	774

=====
Total params: 59489030 (226.93 MB)
Trainable params: 1116806 (4.26 MB)
Non-trainable params: 58372224 (222.67 MB)

Gambar 4.10 Arsitektur model

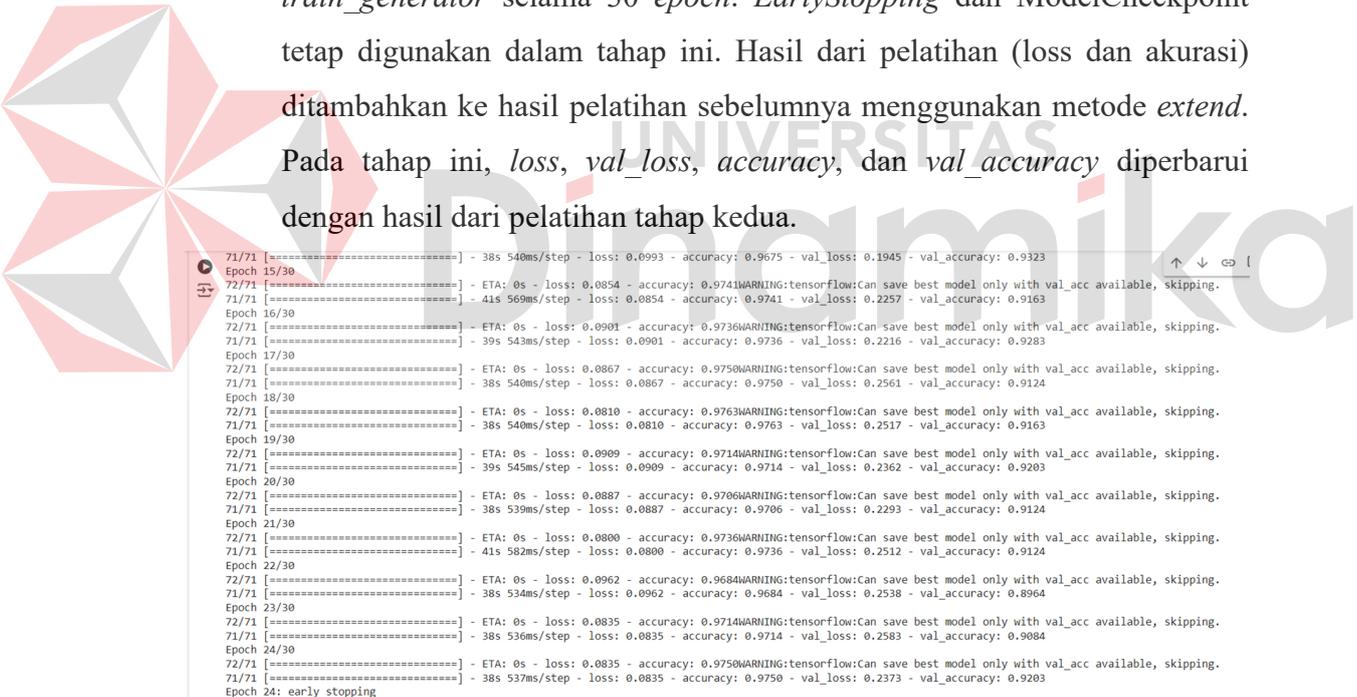
4.4.4 Pelatihan Model

Dalam pelatihan model, Optimizer yang digunakan adalah adam, serta ada beberapa parameter yang digunakan, yaitu :

1. **num_epochs**: Model dilatih selama 30 epoch pada setiap tahap pelatihan.
2. **STEP_SIZE_TRAIN**: Jumlah langkah per epoch selama pelatihan dihitung dengan membagi jumlah sampel dalam train_generator dengan ukuran batch-nya.
3. **STEP_SIZE_TEST**: Jumlah langkah per epoch selama validasi dihitung dengan membagi jumlah sampel dalam test_generator dengan ukuran batch-nya.
4. **EarlyStopping (es)**: Digunakan untuk menghentikan pelatihan lebih awal jika tidak ada perbaikan dalam 'val_loss' setelah 10 epoch (*patience*=10), dengan mode monitoring '*min*'.
5. **ModelCheckpoint (mc)**: Digunakan untuk menyimpan model dengan akurasi validasi terbaik ('val_acc') hanya ketika model mengalami perbaikan.

4.4.5 Langkah Pelatihan

1. Pelatihan Awal : Model dilatih menggunakan data yang dihasilkan oleh *train_generator* selama 30 *epoch*. Kemudian validasi dilakukan dengan *test_generator*. Parameter utama yang dipantau adalah '*loss*', '*val_loss*', '*accuracy*', dan '*val_accuracy*'. *EarlyStopping* digunakan untuk menghentikan pelatihan lebih awal jika tidak ada perbaikan dalam '*val_loss*'. *ModelCheckpoint* menyimpan model terbaik berdasarkan akurasi validasi.
2. *Fine-Tuning* : Model diatur agar seluruh layer menjadi trainable (`base_model.trainable=True`), memungkinkan fine-tuning dari model yang sudah dilatih. Kemudian model kembali dilatih menggunakan *train_generator* selama 30 *epoch*. *EarlyStopping* dan *ModelCheckpoint* tetap digunakan dalam tahap ini. Hasil dari pelatihan (*loss* dan akurasi) ditambahkan ke hasil pelatihan sebelumnya menggunakan metode *extend*. Pada tahap ini, *loss*, *val_loss*, *accuracy*, dan *val_accuracy* diperbarui dengan hasil dari pelatihan tahap kedua.



```

71/71 [=====] - 38s 540ms/step - loss: 0.0993 - accuracy: 0.9675 - val_loss: 0.1945 - val_accuracy: 0.9323
Epoch 15/30
72/71 [=====] - ETA: 0s - loss: 0.0854 - accuracy: 0.9741WARNING:tensorflow:Can save best model only with val_acc available, skipping.
71/71 [=====] - 41s 569ms/step - loss: 0.0854 - accuracy: 0.9741 - val_loss: 0.2257 - val_accuracy: 0.9163
Epoch 16/30
72/71 [=====] - ETA: 0s - loss: 0.0901 - accuracy: 0.9736WARNING:tensorflow:Can save best model only with val_acc available, skipping.
71/71 [=====] - 39s 543ms/step - loss: 0.0901 - accuracy: 0.9736 - val_loss: 0.2216 - val_accuracy: 0.9283
Epoch 17/30
72/71 [=====] - ETA: 0s - loss: 0.0867 - accuracy: 0.9750WARNING:tensorflow:Can save best model only with val_acc available, skipping.
71/71 [=====] - 38s 540ms/step - loss: 0.0867 - accuracy: 0.9750 - val_loss: 0.2561 - val_accuracy: 0.9124
Epoch 18/30
72/71 [=====] - ETA: 0s - loss: 0.0810 - accuracy: 0.9763WARNING:tensorflow:Can save best model only with val_acc available, skipping.
71/71 [=====] - 38s 540ms/step - loss: 0.0810 - accuracy: 0.9763 - val_loss: 0.2517 - val_accuracy: 0.9163
Epoch 19/30
72/71 [=====] - ETA: 0s - loss: 0.0909 - accuracy: 0.9714WARNING:tensorflow:Can save best model only with val_acc available, skipping.
71/71 [=====] - 39s 545ms/step - loss: 0.0909 - accuracy: 0.9714 - val_loss: 0.2362 - val_accuracy: 0.9203
Epoch 20/30
72/71 [=====] - ETA: 0s - loss: 0.0887 - accuracy: 0.9706WARNING:tensorflow:Can save best model only with val_acc available, skipping.
71/71 [=====] - 38s 539ms/step - loss: 0.0887 - accuracy: 0.9706 - val_loss: 0.2293 - val_accuracy: 0.9124
Epoch 21/30
72/71 [=====] - ETA: 0s - loss: 0.0800 - accuracy: 0.9736WARNING:tensorflow:Can save best model only with val_acc available, skipping.
71/71 [=====] - 41s 582ms/step - loss: 0.0800 - accuracy: 0.9736 - val_loss: 0.2512 - val_accuracy: 0.9124
Epoch 22/30
72/71 [=====] - ETA: 0s - loss: 0.0962 - accuracy: 0.9684WARNING:tensorflow:Can save best model only with val_acc available, skipping.
71/71 [=====] - 38s 534ms/step - loss: 0.0962 - accuracy: 0.9684 - val_loss: 0.2538 - val_accuracy: 0.8964
Epoch 23/30
72/71 [=====] - ETA: 0s - loss: 0.0835 - accuracy: 0.9714WARNING:tensorflow:Can save best model only with val_acc available, skipping.
71/71 [=====] - 38s 536ms/step - loss: 0.0835 - accuracy: 0.9714 - val_loss: 0.2583 - val_accuracy: 0.9084
Epoch 24/30
72/71 [=====] - ETA: 0s - loss: 0.0835 - accuracy: 0.9750WARNING:tensorflow:Can save best model only with val_acc available, skipping.
71/71 [=====] - 38s 537ms/step - loss: 0.0835 - accuracy: 0.9750 - val_loss: 0.2373 - val_accuracy: 0.9203
Epoch 24: early stopping

```

Gambar 4.11 Pelatihan Model

4.5 Evaluasi Model

Classification Report yang telah dilakukan menghasilkan *report* seperti pada **Error! Reference source not found.**, dimana setiap kategori memiliki

persentase yang berbeda karena bergantung kepada kualitas dan banyak data yang digunakan untuk training.

	precision	recall	f1-score	support
cardboard	0.97	0.90	0.94	40
glass	0.92	0.92	0.92	50
metal	0.87	1.00	0.93	41
paper	0.93	0.97	0.95	59
plastic	0.93	0.85	0.89	48
trash	1.00	0.92	0.96	13
accuracy			0.93	251
macro avg	0.94	0.93	0.93	251
weighted avg	0.93	0.93	0.93	251

Gambar 4.12 *Classification Report*

1. *Precision* : Persentase prediksi positif yang benar terhadap dengan total prediksi positif.
2. *Recall* : Persentase prediksi positif yang benar terhadap dengan total positif aktual.
3. *F1 Score* : Gabungan antara Precision dan Recall dari model

4.6 Hasil Testing

Hasil testing pertama dilakukan dengan mengambil sebuah gambar sampah dari apel yang telah dimakan. Hasil testing menunjukkan bahwa model memprediksi gambar tersebut sebagai “Trash” karena tidak tergolong pada sampah kardus, kaca, besi, kertas, maupun plastik.

```
[ ] from PIL import Image
path = 'Garbage classification/Garbage classification/trash/trash101.jpg'
img = Image.open(path)
img = img.resize((224, 224))
display(img)
x = keras.preprocessing.image.img_to_array(img)
x = np.expand_dims(x, axis=0)
x = tf.keras.applications.resnet50.preprocess_input(x)

[ ] labels = ['cardboard', 'glass', 'metal', 'paper', 'plastic', 'trash']
classes = model.predict(x)
pred = labels[np.argmax(classes)]
print(classes)
print(pred)

1/1 [=====] - 1s 1s/step
[[3.2161837e-04 1.0379756e-04 7.5658865e-04 2.9832426e-02 4.6818054e-06
 9.6898091e-01]]
trash
```

Gambar 4.13 Hasil Testing

Hasil testing kedua dilakukan lagi dengan mengambil sebuah gambar dari kardus. Hasil testing menunjukkan bahwa model memprediksi gambar tersebut sebagai “cardboard” sesuai dengan model yang dilatih dengan warna dan juga bentuk.

```
from PIL import Image
path = 'cardboard.jpg'
img = Image.open(path)
img = img.resize((224, 224))
display(img)
x = keras.preprocessing.image.img_to_array(img)
x = tf.keras.applications.resnet50.preprocess_input(x)
x = np.expand_dims(x, axis=0)

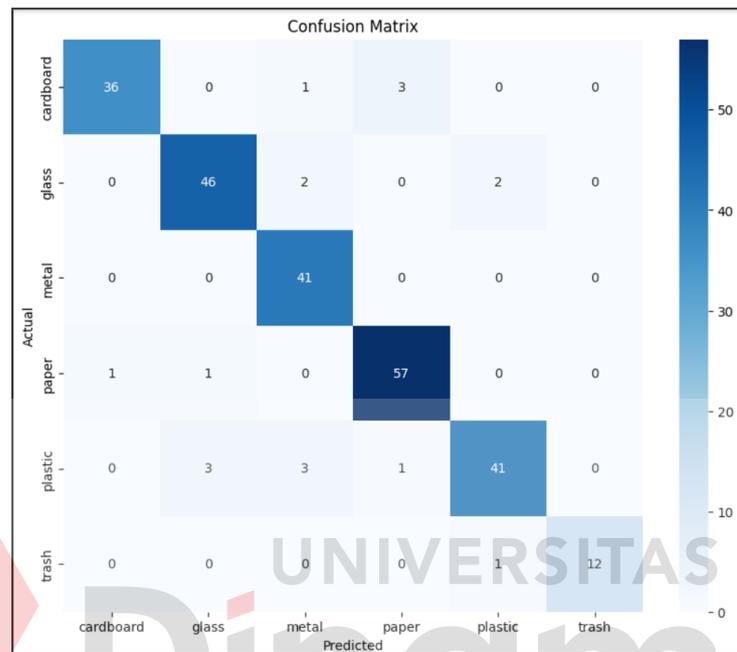
[ ] labels = ['cardboard', 'glass', 'metal', 'paper', 'plastic', 'trash']
classes = model.predict(x)
pred = labels[np.argmax(classes)]
print(classes)
print(pred)

1/1 [=====] - 0s 31ms/step
[[9.9998045e-01 7.9956273e-08 4.3744167e-06 1.3127387e-05 2.0317351e-08
 1.8728704e-06]]
cardboard
```

Gambar 4.14 Hasil Testing 2

4.7 Confusion Matrix

Setelah dilakukan pengecekan Confusion Matrix menghasilkan tabel seperti pada gambar dibawah. Confusion matrix membandingkan antara kondisi nyata (actual) dengan kondisi terprediksi (predicted) dengan warna semakin gelap maka nilai tersebut semakin sering muncul.



Gambar 4.15 Confusion Matrix

4.8 Deployment

Deployment merupakan tahap terakhir dalam *Capstone Project* ini, yaitu dengan menggunakan Watsonx.ai. seperti gambar berikut :

The screenshot shows the IBM Watson Studio interface for a workspace named 'deploy_garbage_cnn'. The main navigation tabs are Overview, Assets, Deployments, Jobs, and Manage. The 'Deployments' tab is active, displaying a summary of deployment status: 3 Deployed and 0 Failed. Below this, there are sections for 'Job runs' (0 Active, 0 Failed last 24 hours) and 'Space history' (No notifications). The 'Assets' section on the left lists three 'CNN Model' assets, each updated '1 day ago'.

Gambar 4.16 Hasil *deployment*

The screenshot shows the 'Assets' tab selected in the IBM Watson Studio interface for the 'deploy_garbage_cnn' workspace. The 'Assets' section on the left shows '3 assets' and '3 Models'. The main content area displays a table of models:

Name	Type	Software specification	Last modified
CNN Model Model	tensorflow_2.12	runtime-23.1-py3.10	1 day ago Service
CNN Model Model	tensorflow_2.12	runtime-23.1-py3.10	1 day ago Service
CNN Model Model	tensorflow_2.12	runtime-23.1-py3.10	1 day ago Service

The table includes checkboxes for selection and a vertical ellipsis for actions. At the bottom, it shows 'Items per page: 20' and '1-3 of 3 items'.

Gambar 4.17 Hasil *deployment 2*

BAB V

PENUTUP

5.1 Kesimpulan

Proyek “*Garbage Classification*” yang telah kami buat berhasil mengembangkan sistem klasifikasi sampah dengan menggunakan model *deep learning*, dengan arsitektur ResNet. Sistem ini mampu mengklasifikasikan sampah ke dalam enam kategori, yaitu kertas, plastik, kaca, logam, kardus, dan sampah lain. Dengan memanfaatkan teknologi *deep learning*, sistem ini menunjukkan peningkatan efisiensi dan akurasi dalam proses pemilahan sampah dibandingkan dengan metode manual. Hal ini menunjukkan bahwa teknologi *Artificial Intelligence* memiliki potensi besar untuk mendukung pengelolaan sampah yang lebih efektif dan efisien, serta dapat mengurangi ketergantungan pada pemilahan manual yang rawan kesalahan dan berisiko terhadap kesehatan. Hasil pengujian menunjukkan bahwa sistem ini dapat diimplementasikan secara praktis, memberikan solusi yang inovatif untuk masalah pengelolaan sampah.

5.2 Saran

Adapun saran untuk pengembangan proyek ini di masa depan adalah sebagai berikut :

1. Lakukan pengujian lebih lanjut pada dataset yang lebih besar dan beragam untuk memastikan generalisasi model.
2. Optimalkan model lebih lanjut untuk meningkatkan akurasi dan efisiensi.
3. Integrasikan model ini dengan sistem manajemen sampah di kota atau daerah tertentu untuk aplikasi nyata.
4. Kumpulkan feedback dari pengguna akhir dan lakukan pembaruan model secara berkala berdasarkan data baru dan umpan balik yang diterima.

DAFTAR PUSTAKA

1. Diambil dari Buku :

Gonzalez, R. C., & Woods, R. E. (2018). *Digital Image Processing* (4th ed.). Pearson.

Kaza, S., Yao, L., Bhada-Tata, P., & Woerden, F. V. (2018). *What a Waste 2.0: A Global Snapshot of Solid Waste Management to 2050*. World Bank Publications.

2. Diambil dari Jurnal :

Cimpan, C., Maul, A., Jansen, M., Pretz, T., & Wenzel, H. (2015). Central sorting and recovery of MSW recyclable materials: A review of technological state-of-the-art, cases, practice and implications for materials recycling. *Journal of Environmental Management*, 156, 181-199.

He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770-778. doi:10.1109/CVPR.2016.90

Hopewell, J., Dvorak, R., & Kosior, E. (2009). Plastics recycling: challenges and opportunities. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 364(1526), 2115-2126.

Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional. *Proceedings of the 25th International Conference on Neural Information Processing Systems (NIPS)*, (pp. 1097-1105).

Morris, J. (2005). Comparative LCAs for Curbside Recycling Versus Either Landfilling or Incineration with Energy Recovery. *International Journal of Life Cycle Assessment*, 273-284.

Pongrácz, E. (2002). *Re-defining the Concepts of Waste and Waste Management: Evolving the Theory of Waste Management*. Finland: University of Oulu.