

# IMPLEMENTASI ALGORITMA CNN MOBILENET UNTUK KLASIFIKASI GAMBAR SAMPAH DI BANK SAMPAH

Achmad Reza Fahcuroji<sup>1</sup>, Madona Yunita Wijaya<sup>2</sup>, Irma Fauziah<sup>3</sup>

<sup>1,2,3</sup>Fakultas Sains dan Teknologi, UIN Syarif Hidayatullah Jakarta

Jl. Ir H. Juanda No. 95, Ciputat, Kec. Ciputat Tim., Kota Tangerang Selatan

Email : [1achmadreza.fachruroji20@mhs.uinjkt.ac.id](mailto:1achmadreza.fachruroji20@mhs.uinjkt.ac.id), [2madona@uinjkt.ac.id](mailto:2madona@uinjkt.ac.id), [3irma.fauziah@uinjkt.ac.id](mailto:3irma.fauziah@uinjkt.ac.id)

**Abstrak** - Sampah merupakan masalah global yang harus diselesaikan agar lingkungan tetap terjaga dengan baik, terutama di negara berkembang seperti Indonesia. Pemahaman yang baik tentang sampah akan berdampak pada pengelolaan sampah yang optimal. Bank sampah merupakan salah satu jalan keluar dalam pengelolaan sampah agar yang awalnya tidak berguna menjadi bernilai jual. Dalam pelaksanaannya, bank sampah harus memiliki pendataan dan transparansi data sampah nasabah secara *real time*. Teknologi menjadi salah satu solusi utama untuk menghasilkan produk digital yang memudahkan masyarakat dalam mengakses informasi secara akurat. Dengan menggunakan algoritma Convolutional Neural Network (CNN), sebuah data citra dapat diprediksi dengan akurasi yang baik. Seiring dengan perkembangan teknologi saat ini, berbagai macam arsitektur hadir, salah satunya adalah Mobilenet. Arsitektur ini memiliki kemampuan untuk menjalankan *model machine learning* pada perangkat *mobile* dan IoT. Selain itu, model yang dihasilkan cukup baik dengan tingkat akurasi sebesar 96% pada sampah Logam, 92% pada sampah Kertas dan Organik, 80% pada sampah Kardus, 76% pada sampah Kaca, dan 72% pada sampah Plastik. Kekurangan yang ada pada model ini ketika melakukan prediksi dengan bentuk yang hampir mirip dan citra yang memiliki banyak objek didalamnya, maka *error* akan semakin besar sehingga ada kemungkinan terjadi kesalahan dalam memprediksi hasil citra sampah.

**Kata Kunci:** CNN, Mobilenet, Sampah, Bank Sampah

## I. PENDAHULUAN

Sampah merupakan masalah global, khususnya di negara berkembang yang harus menjadi perhatian dalam hal edukasi agar kesadaran bahayanya penumpukan sampah dapat meningkat. Sampah didefinisikan sebagai bentuk limbah padat yang berasal dari manusia dan hewan lalu dibuang karena kehadirannya sudah tidak bermanfaat dan tidak diinginkan lagi (Tchobanoglous, 1993). Berdasarkan data SIPSN pada tahun 2022, terdapat timbunan sampah sebanyak 35.833.450,64 ton/tahun dengan total 62,63% sampah terkelola dan 37,37% sampah tidak terkelola. Tandanya, masih ada 13.390.326,06 ton/tahun sampah yang tidak terkelola. Ini adalah masalah utama yang mengkhawatirkan karena dapat menjadi masalah besar untuk lingkungan dan juga kesehatan (Sistem Informasi Pengelolaan Sampah Nasional, 2022).

Dalam penanganan sampah haruslah seimbang, karena jika tidak seimbang akan berpotensi menimbulkan kerusakan dan juga pencemaran lingkungan. Risiko tinggi akan muncul ketika sampah tidak dikelola dengan baik karena akan berdampak negatif bagi kualitas hidup manusia. Oleh karena itu, untuk memastikan keberlanjutan lingkungan yang sehat dimasa kini dan masa mendatang, diperlukan kesadaran dan praktik pada dunia nyata guna mencegah pencemaran serta menjaga kesejahteraan manusia (Nurchahyo, et al., 2019).

Salah satu solusi yang dapat dilakukan dengan mengubah sampah menjadi uang melalui program Bank Sampah. Kegiatan ini memberikan pengajaran kepada masyarakat sekaligus menumbuhkan jiwa kesadaran dalam pengolahan sampah lebih bijak sehingga dapat mengurangi jumlah sampah yang masuk ke Tempat Pembuangan Akhir (TPA), mengurangi paradigma tentang Kumpul-Angkut-Buang, dan memunculkan sifat *Reduce, Reuse, dan Recycle* (3R) (Risawan et al., 2011). Bukan hanya itu, sampah jika dapat kita berdayakan dapat memiliki nilai jual yang tinggi sedemikian sehingga memberikan dampak positif bagi keuangan masyarakat jika dikelola dengan baik (Suryani, 2014). Pelaksanaan bank sampah dasarnya adalah sebagai rekayasa sosial untuk mengajak masyarakat dalam memilah sampah dan menukarkan dengan uang atau barang yang berguna sehingga masyarakat dapat terdidik untuk menghargai sampah jauh lebih bermakna (Dirjen Cipta Karya, 2011).

Seiring perkembangan teknologi yang kian pesat, dalam pengolahan sampah pun harus mengikuti zamannya. Melakukan pendataan sampah kepada nasabah harus ditingkatkan, karena agar terciptanya rasa nyaman dengan transparansi terkait data sampah nasabah setiap melakukan penimbangan. Dengan itu, akan dapat memberikan rasa semangat bagi nasabah yang aktif dalam memberdayakan bank sampah ketika bisa melihat *real time* peningkatan sampah dan juga penghasilan yang didapatkan oleh nasabah. Oleh karena itu,

dibutuhkan sebuah teknologi agar dapat memudahkan nasabah dalam pendataan dengan *mobile apps* untuk bisa mengidentifikasi sampah apa saja yang disetorkan melalui fitur camera. Teknologi *deep learning* dapat digunakan sebagai teknologi dalam proses identifikasi sampah.

Dalam penelitian ini, akan menggunakan teknologi *deep learning* dengan algoritma Convolutional Neural Network (CNN) untuk pengolahan citra data. *Deep Learning* memiliki akurasi yang tinggi, salah satu teknik yang ada pada *deep learning* yang mayoritas digunakan adalah CNN yang merupakan orang pengembangan lanjutan dari metode *Multilayer Perceptron (MLP)* (Putra, 2016). Proses yang terjadi dalam CNN terbagi menjadi *feature extraction layer* yang berguna untuk mengambil diri dari citra data dan menyimpannya untuk digunakan pada langkah selanjutnya dan *fully connected layer* berguna dalam melakukan klasifikasi objek pada citra data yang disimpan sebelumnya (Borugadda et al., 2021). Convolutional Neural Network mengembangkan beberapa macam arsitektur seperti MobileNet, ResNet, dan LeNet. MobileNet adalah arsitektur yang memiliki kemampuan untuk mengurangi ukuran model dan membelah lapisan menjadi dua bagian yaitu *standard convolution* dan *depthwise convolution* (Venkateswarlu et al., 2020). Arsitektur ini disusun dengan memperhatikan jumlah parameter yang relatif minim, sehingga dapat digunakan pada perangkat keras dengan keterbatasan spesifikasi. MobileNet juga mendukung penerapan teknik *transfer learning*, yang memungkinkan adaptasi model yang awalnya dibuat untuk tujuan tertentu ke dalam konteks penggunaan lain. Untuk menjalankan model *machine learning* di perangkat *mobile* dan IoT, MobileNet dapat diintegrasikan dengan TensorFlow Lite (Purnama, 2020).

Berdasarkan masalah di atas, penggunaan teknologi dalam pengelolaan bank sampah harus segera dikembangkan. Melalui penelitian ini, peluang meningkatnya kualitas pendataan dan juga pencairan uang tabungan nasabah bank sampah akan lebih efisien seiring dikembangkannya teknologi *deep learning* yang terfokus menggunakan algoritma *convolutional neural network* dengan arsitektur MobileNet sehingga menghasilkan model yang akurat dalam mengidentifikasi gambar sampah. Hal ini sangat cocok dalam pengembangan *mobile apps*, sehingga warga dapat mudah mengaksesnya ketika penelitian ini dilanjutkan lebih jauh menjadi aplikasi digital.

## II. TINJAUAN PUSTAKA

### A. Convolutional Neural Network

Convolutional Neural Network (CNN/ConvNet) merupakan algoritma dalam *deep*


*learning* yang merupakan evolusi dari Multilayer Perceptron (MLP). Algoritma ini didesain khusus untuk memproses data dalam format dua dimensi, seperti gambar atau suara. Penggunaan CNN terfokus pada klasifikasi data berlabel dengan menerapkan metode *supervised learning*. Dalam *supervised learning*, data dilatih dengan variabel target, dan tujuan utamanya adalah mengelompokkan data ke dalam kategori yang sudah ada.

CNN pertama kali diperkenalkan dengan nama NeoCognitron oleh Kunihiko Fukushima, seorang peneliti di NHK Broadcasting Science Research Laboratories, Kinuta, Setagaya, Tokyo, Jepang (Fukushima,1980). *Idea* tersebut kemudian dikembangkan lebih lanjut oleh Yann LeCun, seorang peneliti di AT&T Bell Laboratories di Holmdel, New Jersey, Amerika Serikat. LeCun berhasil menerapkan model CNN yang disebut LeNet dalam penelitiannya mengenai pengenalan angka dan tulisan tangan (LeCun, 1990).

Pada tahun 2012, Alex Krizhevsky berhasil meraih gelar juara dalam kompetisi ImageNet Large Scale Visual Recognition Challenge 2012 menggunakan implementasi CNN miliknya. Keberhasilan tersebut menandai suatu momen penting yang menunjukkan efektivitas metode Deep Learning, terutama CNN. Prestasi ini membuktikan bahwa CNN mampu mengungguli metode Machine Learning lainnya, seperti SVM, dalam konteks klasifikasi objek pada citra.

### B. Konsep CNN

Cara operasional CNN memiliki persamaan dengan MLP, tetapi dalam CNN, setiap neuron diwakili dalam format dua dimensi, berbeda dengan MLP di mana setiap neuron hanya memiliki dimensi satu.



Gambar 1. Arsitektur MLP


Sebuah MLP seperti yang terlihat pada Gambar 1 memiliki lapisan input (berwarna merah dan biru) dengan setiap lapisan berisi neuron (ditandai oleh lingkaran putih). MLP menerima input data satu dimensi dan menyebarkannya melalui jaringan hingga menghasilkan keluaran. Setiap koneksi antara neuron pada dua lapisan yang bersebelahan memiliki parameter bobot satu dimensi yang menentukan kualitas model. Pada setiap data input di lapisan, operasi linear dilakukan dengan menggunakan bobot yang ada, dan hasil

komputasi tersebut kemudian mengalami transformasi melalui operasi non-linear yang dikenal sebagai fungsi aktivasi.

Pada CNN, data yang dioperasikan dalam jaringan memiliki dimensi dua, sehingga operasi linear dan parameter bobotnya berbeda dengan MLP. Pada CNN, operasi linear dilakukan dengan menggunakan operasi konvolusi, dan bobotnya tidak lagi hanya satu dimensi, melainkan berbentuk empat dimensi yang terdiri dari sekumpulan kernel konvolusi seperti yang ditunjukkan dalam Gambar 2. Dimensi bobot pada CNN adalah

$$\text{neuron input} \times \text{neuron output} \times \text{tinggi} \times \text{lebar}$$

Dikarenakan karakteristik dari proses konvolusi, CNN hanya efektif digunakan pada data yang memiliki struktur dua dimensi, seperti gambar dan suara.




Gambar 2. Proses Konvolusi CNN

### C. MobileNet V2.

MobileNet merupakan model dengan latensi rendah dan konsumsi daya yang minim, diadaptasi untuk memenuhi pembatasan sumber daya dalam berbagai skenario penggunaan. Menurut laporan penelitian, MobileNet V2 berhasil meningkatkan kinerja model seluler yang canggih dalam berbagai tugas dan uji coba, mencakup berbagai ukuran model. Sebagai ekstraktor fitur yang efektif untuk deteksi dan segmentasi objek, MobileNet V2 menunjukkan keunggulan, seperti dalam deteksi, di mana, ketika digunakan bersama dengan Single Shot Detector Lite, MobileNet V2 mencapai kecepatan sekitar 35 persen lebih tinggi dengan akurasi yang setara dengan MobileNet V1.

Arsitektur MobileNetV2 mengeksplorasi representasi input dan output perantara, dan dengan lapisan-lapisan yang merangkum kemampuan model untuk mentransformasi dari konsep tingkat rendah, seperti piksel, ke deskriptor tingkat tinggi, seperti kategori gambar. Penggunaan pintasan dengan koneksi residual konvensional memfasilitasi pelatihan yang lebih cepat dan hasil akurasi yang lebih baik. Meskipun MobileNet V2 tetap menggunakan *depthwise* dan *pointwise convolution*, model ini memperkenalkan dua fitur baru: 1) *bottleneck linear*, dan 2) koneksi pintasan antar

*bottleneck*. Gambar 3 menggambarkan struktur dasar dari arsitektur ini.



Gambar 3. Arsitektur MobileNet V2

Bagian *bottleneck* menghubungkan input dan output pada model, sementara lapisan dalamnya membungkus kemampuan model untuk mentransformasi input dari konsep tingkat rendah (piksel) ke deskriptor tingkat tinggi. Secara keseluruhan, seperti koneksi residu pada CNN tradisional, shortcut antar *bottleneck* memungkinkan pelatihan yang lebih cepat dan meningkatkan akurasi.

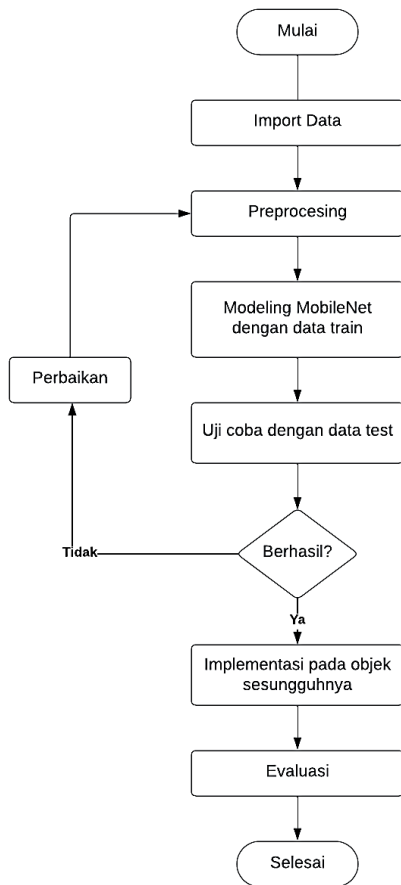
Arsitektur MobileNet V2 melibatkan blok dasar yang mengandung konvolusi yang dapat dipisahkan dalam kedalaman, bersama dengan residu. Struktur ini terdiri dari lapisan konvolusi awal dengan 32 filter, diikuti oleh 19 lapisan *bottleneck residual*. Peneliti telah menyesuaikan arsitektur ini untuk berbagai tingkat kinerja dengan mengatur hyperparameter seperti resolusi gambar input dan pengganda lebar. Jaringan utama dengan resolusi  $1,224 \times 224$  memiliki biaya komputasi sekitar 300 juta perkalian-tambahan dan menggunakan 3,4 juta parameter. Biaya komputasi jaringan bervariasi dari 7 hingga 585 juta perkalian-tambahan, dengan ukuran model berkisar antara 1,7 hingga 6,9 juta parameter.

Perbedaan antara Model MobileNet V1 dan MobileNet V2 mencakup algoritma dan struktur masing-masing model. MobileNet V1 memiliki satu lapisan, sementara MobileNet V2 memiliki dua lapisan, menyebabkan waktu proses MobileNet V2 lebih cepat dibandingkan dengan MobileNet V1. MobileNet V2 menggunakan operasi dua kali lebih sedikit, memberikan akurasi yang lebih tinggi, membutuhkan parameter 30 persen lebih sedikit, dan mencapai kecepatan sekitar 30-40 persen lebih cepat (MobileNet V2).

### III. METODE PENELITIAN

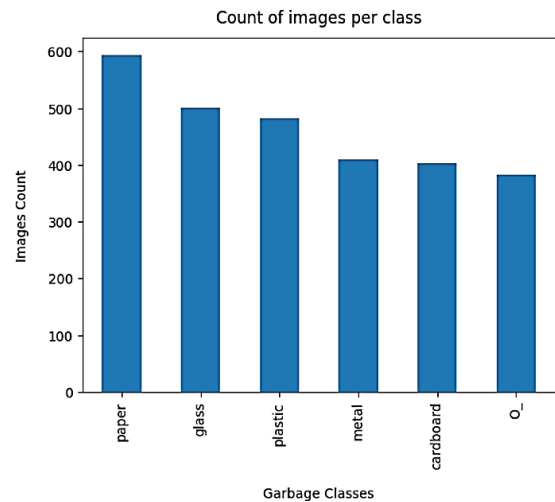
Pada penelitian kali ini menggunakan model CNN untuk mengklasifikasi sampah dengan menggunakan *dataset Waste Classification Data* untuk data anorganik dan *dataset Garbage Classification* untuk data organik yang diperoleh

dari website penyedia dataset yang bernama Kaggle dengan menganalisis image data berupa sampah organik dan anorganik. Alur penelitian ini dapat dilihat pada Gambar 1 sebagai berikut :



Gambar 4. Alur Penelitian

1. Import data dengan cara menghubungkan Google Drive dengan Google Colab sehingga bisa melakukan import data. Selanjutnya, mengubah variabel kelas string menjadi numerik dan juga membuat jalur penyimpanan yang baru pada Google Colab untuk data yang akan dikelola sehingga kita bisa melakukan visualisasi jumlah gambar di masing masing kelasnya.



Gambar 5. Visualisasi Jumlah Gambar per kelas

2. *Preprocessing* pada data yang sudah diinput dengan mengubah ukuran gambar menjadi 224 x 224. Selanjutnya, mengembalikan kembali jenis variabel menjadi string, kemudian dilakukan split data dengan 3 jenis yaitu *data train*, *data validation* dan *data test*.
3. *Modeling* dengan import MobileNet yang dilanjutkan dengan melakukan *split* data sehingga menghasilkan *data train* sebesar 80%, data validasi sebesar 14% dan data test sebesar 6% dari keseluruhan data. Pada proses *split data*, akan mengubah kembali *category* ke awal menjadi *string*.
4. *Train model* dengan *data train* sebanyak 2218 dari 6 kelas dengan merotasi, memperbesar gambarnya, melakukan *flip vertikal* dan *horizontal* serta merubah ukuran *sizenya*, dan training model ini dilakukan dengan total *epoch* sebesar 15.
5. Evaluasi pada model yang sudah dihasilkan lalu melakukan uji coba dengan *data test*, ketika gagal maka akan ada perbaikan dari proses *preprocessing* awal, namun jika sudah berhasil maka akan berlanjut untuk pengujian pada gambar asli yang dihasilkan dari hasil foto menggunakan kamera

#### IV. HASIL DAN PEMBAHASAN

##### A. Pengumpulan Data

Data yang diperoleh berupa gambar dengan format .jpg dari *website* Kaggle kemudian, dipindah ke Google Drive yang nantinya akan dihubungkan dengan Google Colab untuk diolah. Berdasarkan gambar 2 didapatkan data yang terkumpul dengan 6 kelas yang berbeda dan jumlah gambar yang berbeda. Untuk bisa melakukan visualisasi pada kelas data gambar, ada beberapa proses yang dilalui seperti merubah variabel yang awalnya string menjadi numerik, kemudian membuat path baru sebagai lokasi data dengan kelas numerik sehingga



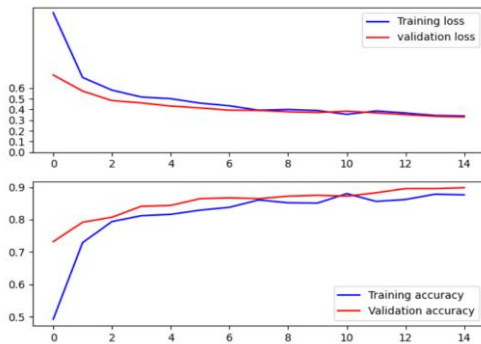
kita bisa visualisasikan sesuai jumlah gambar masing masing kelas.

**B. Processing data**

Data yang dikelola sebanyak 2773 gambar akan melalui rangkaian perubahan ukuran gambar menjadi 224 x 224 dan akan dibagi menjadi 3 data yaitu untuk *data train* sebanyak 2218 (80%), data validasi sebanyak 388 (14%) dan *data test* sebanyak 167 (6%). Selanjutnya, pada *data train* akan dilakukan *rotasi*, *flip vertical* dan *horizontal* dan juga perubahan *weight* dan *height* dengan tujuan mengenali gambar sampah sedetail mungkin.

**C. Pelatihan Data**

Data yang digunakan sebanyak 2218 gambar yang terbagi dalam 6 kelas yaitu *paper*, *glass*, *plastic*, *metal*, *cardboard* dan *organic*. Berikut adalah hasil training dengan *output* grafik



Gambar 6. Grafik Training dan Validation

Gambar 6 menjelaskan tentang *Training Accuracy* dan *Training Loss* pada garis berwarna biru sementara *Validation Accuracy* dan *Validation Loss* pada garis berwarna merah. Dapat disimpulkan dalam hal *Training Accuracy* sangat baik dengan angka 87,65% menunjukkan seberapa benar model dalam mengklasifikasi gambar dan nilai *Training Loss* sebesar 33,86% menunjukkan seberapa baik model dalam memprediksi label pada data train. Kemudian, dalam hal *Validation Accuracy* sangat baik dengan angka 89,84% menunjukkan seberapa benar model dalam mengklasifikasi gambar dari data validasi dan nilai *Validation Loss* sebesar 32,93% menunjukkan seberapa baik model dalam menggeneralisasi pada data validasi. Dengan demikian, model memiliki kinerja yang baik, namun ada ruang untuk meningkatkan generalisasi dan mengurangi *loss* dengan menambahkan lebih banyak data dan *epoch* pada proses pelatihan model CNN sehingga *loss* bisa semakin rendah.

**D. Implementasi dan Uji Coba**

Proses ini menggunakan sampel *data test* yang berisikan kumpulan gambar sampah organik dan anorganik. Penerapan nantinya akan *diexport* ke dalam bentuk *.tflite* sehingga dapat *dideploy* pada

*mobile apps*. Singkatnya, akan memudahkan nasabah untuk melakukan pendataan dan juga penerimaan komisi tabungan dalam satu buah aplikasi, hanya dengan foto menggunakan kamera *Handphone*, akan dapat membaca hasil yang difoto. Selanjutnya, bisa memastikan harga dari masing masing jenis barang dan total uang komisi akan masuk kedalam dompet digital.

Tabel 1. Hasil Prediksi menggunakan Mobilenet

Keterangan	Hasil Prediksi
Gambar botol plastik dikategorikan sebagai <i>plastic</i>	
Gambar kaleng dikategorikan sebagai <i>metal</i>	
Gambar kertas dikategorikan sebagai <i>paper</i>	
Gambar kardus dikategorikan sebagai <i>cardboard</i>	
Gambar botol kaca dikategorikan sebagai <i>glass</i>	

**E. Pengujian**

Pada fase pengujian, dilakukan pengambilan gambar pada Bank Sampah Cinangka dengan total gambar sebanyak 25 gambar dari kelas yang sudah dikelola, maka didapatkan hasilnya.

Tabel 2. Hasil percobaan dan akurasi

Jenis Sampah	Benar	Salah	Akurasi	Error
Plastik	18	7	72%	28%
Metal	24	1	96%	4%
Cardboard	20	5	80%	20%
Glass	19	6	76%	24%
Paper	23	2	92%	8%
Organik	23	2	92%	8%

Dari hasil pengujian pemilahan sampah sudah bagus dengan tingkat akurasi 96% pada sampah *Metal*, 92% pada sampah *Paper* dan *Organic*, 80% pada sampah *Cardboard*, 76% pada sampah *Glass*, dan 72% pada sampah *Plastic*. Kekurangan pada sistem ini ketika mengenal dan menganalisa objek plastik dan *glass* yang memiliki bentuk yang serupa seperti botol plastik dan botol kaca, sering terjadi kesalahan dalam hasil prediksinya, hampir serupa dengan *cardboard* yang memiliki bentuk serupa seperti paper sehingga beberapa kali terdapat kesalahan dalam prediksi. Akurasi yang bagus dalam mengenal dan menganalisa data gambar *paper*, *organic* dan *metal* yang memiliki akurasi diatas 90%.

## V. KESIMPULAN DAN SARAN

### Kesimpulan

Penelitian ini menjadi sebuah harapan besar dalam penanggulangan sampah dengan fokus pada identifikasi jenis sampah.

1. Terdapat 6 kelas yang dapat diprediksi yaitu plastik, *metal*, *cardboard*, *glass*, *paper* dan organik.
2. Melalui metode *Convolutional Neural Network (CNN)* peneliti mendapatkan hasil akurasi yang cukup memuaskan. Dengan tingkat akurasi yang baik, akan memudahkan pendataan dan transparansi data setiap kali melakukan penimbangan di bank sampah. Sudah cukup bukti dapat dilihat pada tabel 2 bahwasannya model dari penelitian ini memberikan harapan besar untuk pendataan dan pengelolaan Bank sampah lebih baik lagi.
3. Namun, model masih memiliki tingkat loss yang cukup tinggi pada kedua *dataset* yaitu data train dan data validasi sehingga penambahan data dan epoch bisa membantu untuk mengurangi loss dan meningkatkan performa model.

### Saran

Rencana kedepan agar bisa melanjutkan pembuatan *Mobile apps* guna memaksimalkan pendataan dan transparansi data sehingga profesional bank sesungguhnya dapat terasa di setiap bank sampah yang menggunakan aplikasi tersebut.

### DAFTAR PUSTAKA

- Borugadda, P., Lakshmi, R., & Govindu, S. (2021). Classification of Cotton Leaf. *Current Journal of Applied Science and Technology*
- Direktorat Pengembangan Penyehatan Lingkungan Permukiman Dirjen Cipta Karya Kementerian Pekerjaan Umum, 2011, Materi Bidang Sampah I Diseminasi dan Sosialisasi Keteknikan Bidang PLP, Direktorat Pengembangan Penyehatan Lingkungan Permukiman Dirjen Cipta Karya Kementerian Pekerjaan Umum, Jakarta
- Eka Putra, W. S. (2016). Klasifikasi Citra Menggunakan Convolutional Neural Network (CNN) pada Caltech 101. *Jurnal Teknik ITS*, 5.
- K. Fukushima. (1980). "Neocognitron: A Self-Organizing Neural Network Model for a Mechanism of Pattern Recognition Unaffected by Shift in Position," *Biological Cybernetics*.
- MobileNet V2, <https://medium.com/nodeflux/mobilenet-deteksi-objek-pada-platform-mobile-bbbf3806e4b3>
- Nurcahyo, E., & Ernawati, D. (2019). Peningkatan Kesadaran Masyarakat Dalam Pengelolaan Sampah Rumah Tangga Di Desa Mambulugo, Kabupaten Buton. In *Jurnal Pengabdian Masyarakat*, e-ISSN 2598-2052 Vol. 02 Nomor 02. 2019. 31-37.
- P,E,Suartika,Wayan,I., Wijaya, Yudhi, Arya., Soelaiman, Rully. (2016). Klasifikasi Citra Menggunakan Convolutional Neural Network (Cnn) pada Caltech 101. *Journal Teknik ITS Vol. 5, No. 1, (2016) ISSN: 2337-3539 Technology*,
- Purnama, I. N. (2020). Herbal Plant Detection Based on Leaves Image Using Convolutional Neural Network With Mobile Net Architecture. *JITK (Jurnal Ilmu Pengetahuan Dan Teknologi Komputer)*, 6(1), 27-32. <https://doi.org/10.33480/jitk.v6i1.1400>
- Risawan., Sunoko, R, H., Hadiyanto, A.(2011). Pengelolaan sampah Rumah Tangga di Kecamatan Daha Selatan. *Jurnal Ilmu Lingkungan. Jurnal UNDIP*, Vol. 9. No. 1

- Sistem Informasi Pengelolaan Sampah Nasional.  
(n.d). Sistem Informasi Pengelolaan Sampah Nasional. <https://sipsn.menlhk.go.id/sipsn/>
- Suryani, Sri, Anih. (2014). Peran Bank Sampah Dalam Efektivitas Pengelolaan Sampah (Studi Kasus Bank Sampah Malang). *Aspirasi* Vol. 5, No. 1, Juni 2014
- Tchobanoglous, G., Teisen H., Eliassen, R, 1993, *Integrated Solid Waste Management*, Mc.Graw Hill, Kogakusha, Ltd
- Venkateswarlu, I., Kakarla, J., & Prakash, S. (2020). Face mask detection using MobileNet and Global Pooling Block. *IEEE*.
- Y. LeCun, 1990, "Handwritten Digit Recognition with a Back-Propagation Network,".