

EXPLORE

Jurnal Sistem Informasi & Telematika (Telekomunikasi, Multimedia & Informatika)

Indra Kurniawan, Ahmad Faiq Abror

KOMPARASI METODE KOMBINASI SELEKSI FITUR DAN MACHINE LEARNING K-NEAREST NEIGHBOR PADA DATASET LABEL HOURS SOFTWARE EFFORT ESTIMATION

Fenty Ariani, Arnes Yuli Vandika, Handy Widjaya

IMPLEMENTASI ALAT PEMBERI PAKAN TERNAK MENGGUNAKAN IOT UNTUK OTOMATISASI PEMBERIAN PAKAN TERNAK

Robby Yuli Endra, Ahmad Cneus, Freddy Nur Affandi, Deni Hermawan

IMPLEMENTASI SISTEM KONTROL BERBASIS WEB PADA SMART ROOM DENGAN MENGGUNAKAN KONSEP INTERNET OF THINGS

Tri Susilowati, Suepto, Nungsiyati, Tomi Adi Kartika, Nur Zaman

PENERAPAN METODE SIMPLE ADDITIVE WEIGHTING (SAW) PADA AMRI SUPERMARKET BANJAR JAYA UNTUK PEMILIHAN KARYAWAN TERBAIK

Erlangga, Taqwan Thamrin, Panji Maulana, Nico Susanto

BUS TRACKER – SISTEM LACAK LOKASI CALON PENUMPANG, LOKASI BUS DAN PERKIRAAN WAKTU KEDATANGAN BUS

Stephen, Raymond, Handri Santoso

APLIKASI CONVOLUTION NEURAL NETWORK UNTUK MENDETEKSI JENIS-JENIS SAMPAH

Freddy Nur Afandi, Ramses Parulian Sinaga, Yuthsi Aprilinda, Fenty Ariani

IMPLEMENTASI FACE DETECTION PADA SMART CONFERENCE MENGGUNAKAN VIOLA JONES

Dani Yusuf, Freddy Nur Afandi

APLIKASI MONITORING BASE TRANSCEIVER STATION BERBASIS ANDROID MENGGUNAKAN METODE LOCATION BASED SERVICE

Dede Aprilia Haspita, Jimi Ali Baba

DECISION SUPPORT SYSTEM(SISTEM PENDUKUNG KEPUTUSAN) PENERIMAAN PESERTA DIDIK BARU

Reni Nursyanti, R.Yadi Rakhman Alamsyah, Surya Perdana

PERANCANGAN APLIKASI BERBASIS WEB UNTUK MEMBANTU PENGUJIAN KUALITAS KAIN TEKSTIL OTOMOTIF (STUDI KASUS PADA PT. ATEJA MULTI INDUSTRI)



Jurnal Sistem Informasi dan Telematika
(Telekomunikasi, Multimedia, dan Informasi)
Volume 10, Nomor 2, Oktober 2019

NO	JUDUL PENELITIAN / NAMA PENULIS	HALAMAN
1.	KOMPARASI METODE KOMBINASI SELEKSI FITUR DAN MACHINE LEARNING K-NEAREST NEIGHBOR PADA DATASET LABEL HOURS SOFTWARE EFFORT ESTIMATION Indra Kurniawan, Ahmad Faiq Abror	83-89
2.	IMPLEMENTASI ALAT PEMBERI PAKAN TERNAK MENGGUNAKAN IOT UNTUK OTOMATISASI PEMBERIAN PAKAN TERNAK Fenty Ariani, Arnes Yuli Vandika, Handy Widjaya	90-97
3	IMPLEMENTASI SISTEM KONTROL BERBASIS WEB PADA SMART ROOM DENGAN MENGGUNAKAN KONSEP INTERNET OF THINGS Robby Yuli Endra , Ahmad Cucus, Freddy Nur Affandi, Deni Hermawan	98-106
4	PENERAPAN METODE SIMPLE ADDITIVE WEIGHTING (SAW) PADA AMRI SUPERMARKET BANJAR JAYA UNTUK PEMILIHAN KARYAWAN TERBAIK Tri Susilowati,Sucipto, Nungsiyati, Tomi Adi Kartika,Nur Zaman	107-115
5	BUS TRACKER – SISTEM LACAK LOKASI CALON PENUMPANG, LOKASI BUS DAN PERKIRAAN WAKTU KEDATANGAN BUS Erlangga,Taqwan Thamrin, Panji Maulana, Nico Susanto	116-121
6	APLIKASI CONVOLUTION NEURAL NETWORK UNTUK MENDETEKSI JENIS-JENIS SAMPAH Stephen, Raymond, Handri Santoso	122-132
7	IMPLEMENTASI FACE DETECTION PADA SMART CONFERENCE MENGGUNAKAN VIOLA JONES Freddy Nur Afandi, Ramses Parulian Sinaga, Yuthsi Aprilinda, Fenty Ariani	133-138
8	APLIKASI MONITORING BASE TRANSCIEVER STATION BERBASIS ANDROID MENGGUNAKAN METODE LOCATION BASED SERVICE Dani Yusuf, Freddy Nur Afandi	139-144
9	DECISION SUPPORT SYSTEM(SISTEM PENDUKUNG KEPUTUSAN) PENERIMAAN PESERTA DIDIK BARU Dede Aprilia Haspita, Jimi Ali Baba	145-152
10	PERANCANGAN APLIKASI BERBASIS WEB UNTUK MEMBANTU PENGUJIAN KUALITAS KAIN TEKSTIL OTOMOTIF (STUDI KASUS PADA PT. ATEJA MULTI INDUSTRI) Reni Nursyanti, R.Yadi Rakhman Alamsyah, Surya Perdana	153-159

Fakultas Ilmu Komputer
Universitas Bandar Lampung

JIST	Volume 10	Nomor 2	Halaman	Lampung Oktober 2019	ISSN 2087 – 2062 E-ISSN 2686-181X
------	-----------	---------	---------	-------------------------	--------------------------------------

**Jurnal Manajemen Sistem Informasi dan Telematika
(Telekomunikasi, Multimedia & Informatika)**

Program Studi Teknik Informatika
Fakultas Ilmu Komputer
Universitas Bandar Lampung

PENANGGUNG JAWAB

Rektor Universitas Bandar Lampung

Ketua Tim Redaksi:

Ahmad Cucus, S.Kom, M.Kom

Wakil Ketua Tim Redaksi:

Marzuki, S.Kom, M.Kom

TIM PENYUNTING :

PENYUNTING AHLI (MITRA BESTARI)

Prof. Mustofa Usman, Ph.D (Universitas Lampung)

Prof. Wamiliana, Ph.D (Universitas Lampung)

Akmal Junaidi, Ph.D (Universitas Lampung)

Handri Santoso, Ph.D (Institute Sains dan Teknologi Pradita)

Dr. Iing Lukman, M.Sc. (Universitas Malahayati)

Penyunting Pelaksana:

Robby Yuli Endra S.Kom., M.Kom

Yuthsi Aprilinda, S.Kom, M.Kom

Fenty Ariani, S.Kom., M.Kom

Pelaksana Teknis:

Wingky Kesuma, S.Kom

Shelvi, S.Kom

Alamat Penerbit/Redaksi:

Pusat Studi Teknologi Informasi - Fakultas Ilmu Komputer
Universitas Bandar Lampung
Gedung M Lantai 2 Pascasarjana
Jl. Zainal Abidin Pagar Alam no.89 Gedong Meneng Bandar Lampung
Email: explore@ubl.ac.id

PENGANTAR REDAKSI

Jurnal explore adalah jurnal yang diprakasai oleh program studi Informatika, Fakultas Ilmu Komputer Universitas Bandar Lampung, yang di kelola dan diterbitkan oleh Fakultas Ilmu Komputer / Pusat Sudi Teknologi Informasi.

Pada Edisi ini, explore menyajikan artikel/naskah dalam bidang teknologi informasi khususnya dalam pengembangan aplikasi, pengembangan machine learning dan pengetahuan lain dalma bidang rekayasa perangkat lunak, redaksi mengucapkan terima kasih dan selamat kepada penulis makalah ilmiah yang makalahnya kami terima dan di terbitkan dalam edisi ini, makalah ilmiah yang ada dalam jurnal ini memberikan kontribusi penting pada pengembangan ilmu dan teknologi.

Selain itu, sejumlah pakar yang terlibat dalam jurnal ini telah memberikan kontribusi yang sangat berharga dalam menilai makalah yang dimuat, oleh sebab itu, redaksi menyampaikan banyak terima kasih.

Pada kesempatan ini redaksi kembali mengundang dan memberikan kesempatan kepada para peneliti, di bidang pengembangan perangkat lunak untuk mempublikasikan hasil penelitiannya dalam jurnal ini.

Akhirnya redaksi berharap semoga makalah dalam jurnal ini bermanfaat bagi para pembaca khususnya bagi perkembangan ilmu dan teknologi dalam bidang perekaan perangkat lunak dan teknologi pada umumnya.

REDAKSI

APLIKASI CONVOLUTION NEURAL NETWORK UNTUK MENDETEKSI JENIS-JENIS SAMPAH

Stephen¹, Raymond², Handri Santoso³

¹Program Studi Human Computer Interaction, Fakultas Ilmu Hayati, Surya University
Tangerang, Banten, Indonesia, 15143

²Institut Sains dan Teknologi Pradita, Gading Serpong, Tangerang, Banten, Indonesia, 15810
Stephenmulyadi97@gmail.com, vengeancenator@gmail.com, handri.santoso@pradita.ac.id

ABSTRAK

Sampah merupakan permasalahan di berbagai negara dunia, termasuk di Indonesia. Negara Indonesia merupakan negara penyumbang sampah plastik terbesar kedua di dunia. Pengolahan sampah merupakan salah satu cara untuk mengurangi sampah yang dihasilkan oleh masyarakat. Pemisahan jenis sampah merupakan tahapan awal sebelum dari proses daur ulang dilakukan. Penginderaan jenis dan bentuk sampah dengan kamera adalah satu metode yang menantang dalam penelitian di bidang computer vision. Dengan menggunakan metode ini dapat membuat sistem pemilahan sampah yang otomatis. Pada penelitian ini akan menentukan model CNN (Convolutional Neural Network) yang memiliki performa paling baik dalam memilah sampah dengan metode transfer learning. Transfer learning dalam penelitian ini menggunakan pre-trained model dari ImageNet. Hasil penelitian menunjukkan bahwa model CNN yang paling baik adalah Resnet 50. Nilai akurasi yang didapatkan dari train adalah 78% dan 90%. Sedangkan nilai akurasi dari validation sebesar 74% dan 80%. Dalam penelitian ini untuk dapat menerapkan teknologi pemisahan sampah secara otomatis pada tempat sampah maka dapat menggunakan model Resnet 50 apabila menggunakan server atau komputer dengan spesifikasi yang tinggi. Apabila menggunakan perangkat controller seperti Raspberry Pi dapat menggunakan model CNN MobileNet

Kata Kunci : Computer Vision, CNN, Image Classification

ABSTRACT

Waste is a problem in every world country, including in Indonesia. Indonesia is the second largest contributor of plastic waste in the world. Waste management is one way to reduce waste generated by the community. Separation of types of waste is an initial step before the recycling process is carried out. Sensing the types and forms of waste with a camera is a challenging method in research in the field of computer vision. Using this method can create an automatic waste sorting system. This research will determine the CNN (Convolutional Neural Network) model that has the best performance in sorting waste by the method of transfer learning. Transfer learning in this study uses a pre-trained model from ImageNet. The results showed that the best CNN model was Resnet 50. The accuracy value obtained from the train was 78% and 90%. While the accuracy value of validation is 74% and 80%. In this research, to be able to apply waste separation technology automatically to the trash, it can use the Resnet 50 model when using a server or computer with high specifications. When using a controller device such as the Raspberry Pi you can use the CNN MobileNet model

Keywords : computer vision, CNN, Image Classification

1. PENDAHULUAN

Sampah merupakan permasalahan yang dihadapi setiap negara. Setiap tahun jumlah dan jenis sampah meningkat seiring dengan bertambahnya jumlah penduduk. Di Indonesia, pada tahun 1990, 220 juta penduduk perkotaan menghasilkan kurang lebih 300.000 ton sampah per hari. Tahun 2000, 2.9 miliar orang yang tinggal di perkotaan menghasilkan 3 juta ton limbah sampah per hari. Pada tahun 2025 diperkirakan akan terus meningkat mencapai puluhan juta ton sampah per harinya [1].

Jenis sampah dapat dibagi berdasarkan bahan, tingkat kebahayaan, dan tempat atau bidang sampah

dihasilkan seperti sampah industry atau sampah rumah tangga. Selain itu, sampah dapat dibagi menjadi sampah organik dan anorganik. Dari jenis-jenis sampah yang ada sampah yang dikenal dengan *Municipal Solid Waste (MSW)* merupakan sampah yang paling banyak dihasilkan. Sampah ini dihasilkan oleh rumah tangga, perkantoran, hotel, sekolah, dan lain-lain. Berdasarkan data dari United States Environmental Protection Agency (EPA) mencatat bahwa sampah ini dari 1960 sampai 2012 terus mengalami kenaikan. Pada tahun 1960 terhitung 88 juta ton sampah dan pada tahun 2012 terhitung 250 juta ton sampah [2][3].

Indonesia merupakan salah satu negara berkembang di Asia yang menyumbang sampah ke-2 didunia. Berdasarkan sumber berita, Indonesia merupakan negara penyumbang sampah plastik terbesar kedua didunia setelah negara Cina. Sebesar 80% atau 3.21 juta ton sampah plastik yang dibuang oleh masyarakat Indonesia dibuang menuju laut [4]. Hal ini dapat menyebabkan pencemaran air yang berdampak banyaknya ikan keracunan sampah plastik. Seperti pada kasus pada tahun 2018, bangkai ikan paus ditemukan terdampar dan memiliki sampah plastik sebesar 6 kilogram di dalam perutnya [5]. Selain itu, berdasarkan data SWI (*Sustainable Waste Indonesia*), Nagara Indonesia masih belum efektif dalam mengolah sampah. Sebesar 24% sampah Indonesia tidak dikelola, 7% sampah berhasil didaur ulang, dan 69% sampah berakhir di TPA (Tempat Pembuangan Akhir). Dengan sampah anorganik atau sampah yang sulit terurai sebesar 40% [6].

Untuk dapat mengatasi permasalahan sampah telah banyak dilakukan cara seperti pengolahan sampah yang lebih efektif, daur ulang sampah, dan pengurangan penggunaan sampah. Daur ulang sampah merupakan salah satu cara yang dapat memberikan dampak positif bagi lingkungan dan dapat meningkatkan ekonomi negara. Hal ini dapat terjadi karena dengan melakukan daur ulang dapat membuka lapangan kerja baru, menjaga lingkungan dan meningkatkan kesehatan masyarakat karena lingkungan tidak bersih [7]. Dalam melakukan daur ulang sampah diperlukan beberapa langkah yang harus dilakukan. Tahap pertama sampah harus dikumpulkan terlebih dahulu. Selanjutnya sampah akan di proses pemilahannya sesuai dengan jenis dan bahan. Langkah berikutnya proses manufaktur, Pada langkah ini sampah yang sudah dipisah akan mulai didaur ulang sesuai dengan jenisnya masing-masing. Dan terakhir setelah selesai dalam manufaktur sampah baru dapat digunakan kembali sebagai produk baru [8].

Computer vision merupakan salah satu teknologi yang mempelajari bagaimana sebuah computer dapat melihat secara visual dan memahami visual yang terlihat [9]. *Image classification* atau pengkategorian gambar merupakan salah satu fitur yang ada dalam teknologi *computer vision*. *Image classification* memiliki banyak fungsi untuk membedakan wilayah pada peta satelit, mengategorikan barang, dan lain-lain. Metode algoritma dari *image classification* ada beberapa macam seperti K-means, SVM (*Support Vector Machine*), dan CNN (*Convolutional Neural Network*) [10].

CNN merupakan perkembangan dari metode ANN (*Artificial Neural Network*) yang berfokus pada pemrosesan gambar, video, dan suara. CNN memiliki sistem kerja yang sama seperti ANN dengan menggunakan prinsip kerja sel otak manusia. Urutan dari algoritma CNN dimulai dari *pre-processing* dalam perubahan data gambar seperti ukuran dan pengurangan *noise*. Selanjutnya deteksi *regions of interest* (ROI), bertugas untuk menghilangkan *background*, pengambilan fitur gambar, Pengenalan objek memiliki fungsi untuk mencocokkan kesamaan fitur yang didapat dengan objek pada gambar. Langkah terakhir pengambilan keputusan seperti hasil pergerakan dari gambar, gambar sama atau tidak, dan lain-lain [11].

CNN terdiri dari berbagai jenis *layer* yaitu *convolution layer*, *pooling layer*, dan *fully connected layer*. *Convolution layer* dan *pooling layer* merupakan *layer* yang menyebabkan ANN dan CNN berbeda pada ANN tidak ada kedua *layer* tersebut. Kedua *layer* tersebut memiliki peran dalam tahap dalam melakukan filter gambar untuk menemukan fitur. Akan tetapi, fungsi dan cara kerja *fully connected layer* pada CNN merupakan perhitungan ANN sehingga memiliki tugas untuk menentukan hasil fitur dengan label yang telah tersedia [12].

Perkembangan dan penelitian mengenai algoritma CNN telah banyak dilakukan. Penelitian yang dilakukan adalah meningkatkan akurasi, mengurangi resource, dan mengurangi error dari algoritma CNN. Hal ini dapat dilakukan dengan mengubah *layer* dari CNN. Pada penelitian-penelitian yang telah dilakukan terdapat beberapa model CNN yang telah dibuat dan dihitung untuk mendapatkan hasil yang maksimal. Model-model tersebut adalah AlexNet, VGG, Resnet, Inception, MobileNet, dan lain-lain. Masing-masing model yang telah ada memiliki kompleksitas, bentuk *layer*, dan jumlah *layer* yang berbeda-beda [13].

Dalam penelitian ini akan dilakukan analisa mengenai model algoritma CNN yang sesuai untuk dapat melakukan pemilahan sampah secara maksimal. Sehingga algoritma ini dapat digunakan secara langsung untuk implementasi pemisahan sampah secara otomatis menggunakan sistem. Penelitian ini bertujuan untuk mengurangi waktu dan mempermudah proses pengumpulan dan pemisahan sampah dalam tahapan daur ulang sampah.

2. STUDI LITERATUR

A. Penelitian Serupa

Penelitian berjudul “*Classification of Trash for Recyclability Status*” meneliti mengenai pengenalan

objek dengan menggunakan algoritma SVM dan CNN. Dalam penelitian ini sampah dibagi menjadi 6 kelas berdasarkan bahan yaitu kertas, kaca, plastik, besi, kardus, dan *trash*. Dalam penelitian ini SVM yang dibuat menggunakan *radial basis kernels*. Dengan hasil akurasi yang mencapai 63% dan error 30%. Sedangkan algoritma CNN yang dibuat adalah CNN dengan 5 convolution layer, 3 pooling layer dan 3 fully connect layer. Hasil akurasi yang didapatkan menggunakan algoritma ini 22% [14].

Pembuatan tempat pemisah sampah menggunakan computer vision diteliti dalam penelitian yang berjudul “*Intelligent Waste Separator*”. Tempat pemisah sampah ini memiliki sistem berbasis reward menggunakan kartu RFID. Sampah yang dipisahkan adalah sampah kaleng, botol plastik, dan sampah alat makan plastik. Algoritma yang digunakan untuk mengkategorikan gambar adalah k-NN. Dalam penelitian ini dilakukan perhitungan Hu’s Invariant Moments (HIM) untuk mengekstrak fitur dari gambar binary untuk menghitung jarak metrik. Hasil yang didapatkan pada uji coba algoritma ini adalah 98.33 % akurasi pada uji coba 20 sampah [15].

Penelitian yang berjudul “*Artificial Intelligence in Automated Sorting in Trash Recycling*” membahas mengenai pemilahan sampah berdasarkan gambar menggunakan algoritma CNN, k-NN, SVM, dan RF (*Random Forest*). Model CNN yang diteliti dalam penelitian ini adalah VGG 16 dan AlexNet. Jenis sampah yang akan dibandingkan adalah plastik, kaca, besi, dan kertas. Hasil akhir akurasi dari penelitian ini adalah VGG 16 93%, AlexNet 91%, k-NN 88%, SVM 80%, dan RF 85% [16].

Pembahasan mengenai pengkategorian sampah menggunakan computer vision juga dibahas dalam penelitian berjudul “*A Computer Vision System to Localize and Classify Waste on the Streets*”. Pada penelitian ini algoritma yang digunakan adalah CNN dengan model GoogleNet atau Inception. Penelitian ini melakukan *localization* sehingga dapat dikatakan tipe CNN yang digunakan adalah R-CNN. Penelitian ini mengembangkan model dengan menggunakan OverFeat model yang digabungkan dengan GoogleNet. Dalam penelitian ini sampah dikategorikan menjadi 5 yaitu sampah kemasan minuman dan makanan, sampah rokok, daun, kertas, dan sisa makanan. Penelitian ini merupakan salah satu penelitian yang dapat menghasilkan lebih dari satu *output* dari satu gambar uji coba [17].

3. METODELOGI PENELITIAN

Proses Penelitian

Proses *training* algoritma CNN dilakukan menggunakan *transfer learning*. Model CNN yang akan diteliti adalah VGG 16, Mobilenet V1, Inception V3, dan Resnet 50. Pemilahan sampah yang dilakukan dibagi menjadi 4 jenis sampah yaitu sampah plastik, kaca, besi, dan lain-lain. Data *train* yang dikumpulkan berupa gambar sampah berdasarkan jenisnya. Penggunaan metode *cross validation* digunakan untuk menghitung nilai performa dari masing-masing model CNN. Hasil dari *cross validation* adalah akurasi dari *train* dan *validation*. Jumlah *cross validation* yang dilakukan sebanyak 5 kali sehingga masing-masing gambar dibagi menjadi 5 sama rata dan 25% dari data tersebut dijadikan data *validation*. Total jumlah gambar yang dikumpulkan sebanyak 1,746 gambar dengan 4 kelas. Jumlah gambar sampah plastik sebagai data *train* sebanyak 465-466 gambar dan data *validation* sebanyak 116-117 gambar. Jumlah gambar sampah kaca sebagai data *train* sebanyak 383-384 gambar dan data *validation* 95-96 gambar. Gambar data *train* sampah besi sebanyak 339-340 gambar dan data *validation* sebanyak 84-85 gambar. Gambar data *train* sampah lain-lain sebanyak 116-117 dan data *validation* sebanyak 52-53 gambar.

Selain itu, dalam penelitian ini akan dilakukan perbandingan 2 jenis cara *transfer learning* model CNN. Cara pertama adalah melakukan *freeze* semua layer kecuali *fully connected layer* dan cara kedua menambahkan model cara pertama dengan melakukan *unfreeze layer* terakhir dari sebelum *fully connected layer*. Masing-masing cara akan menggunakan data yang sama dan sumber pembelajaran atau *train* pertama dengan nilai *weight* yang sama yaitu ImageNet. Model yang dilatih dalam ImageNet menggunakan sekitar 1,2 juta gambar dengan 1000 jenis kelas.

Model algoritma CNN dibuat menggunakan Bahasa pemrograman python dengan batuan *library* tensorflow dan keras. Selain itu, *library* opencv digunakan untuk membaca gambar dan mengambil gambar menggunakan kamera. Jenis perangkat yang digunakan untuk melakukan *training* algoritma adalah laptop Lenovo ideapad 330 dengan spesifikasi :

- Prosesor: 8th Gen Intel Quad Core i5-8250U
- RAM: 8 GB

Proses train algoritma

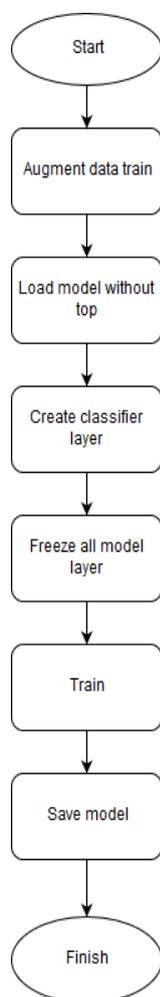
Gambar 1 merupakan proses atau alur program algoritma CNN yang dilakukan. *Augment* data *train* merupakan mengubah gambar supaya seolah-olah gambar menjadi banyak. Dalam hal ini gambar data

train diubah berdasarkan *scale* dan *flip*. Selain itu, pada langkah ini dilakukan *resize* gambar sesuai dengan *input* yang disarankan dari masing-masing model yaitu (224,224) dan (299,299).

Selain itu, perlu adanya penyediaan data *train* dan *validation* sehingga dapat dilakukan perhitungan akurasi *train* dan *validation* model secara terpisah

Tahap Pemuatan model CNN menggunakan model yang telah dilakukan *train* oleh data ImageNet. Model yang diambil merupakan model tanpa *fully connected layer*. Hal ini dilakukan karena *fully connected layer* ImageNet dengan penelitian ini berbeda dalam jumlah kelas yang ingin diprediksi.

Tahap pembuatan *classifier layer* atau *fully connected layer* dilakukan dengan menggunakan GAP untuk membuat *input* tensor menjadi 1x1 matriks. Jumlah *hidden layer* yang dibuat dalam *layer* ini adalah 1. Selain itu, *layer* terakhir *output* menghasilkan 4 nilai prediksi yaitu kaca, besi, plastik, dan lain-lain.



Gambar 1. Flowchart proses train model CNN

Tahap *freeze layer* dilakukan untuk menutup *layer* pada model CNN supaya nilai *weight* pada *layer-layer* model yang telah dilatih dengan data sebelumnya tidak mengalami perubahan. Akan tetapi, penelitian ini akan melakukan dua acara *transfer learning* maka pada *layer* yang dilakukan *unfreeze* akan dapat mengubah nilai *weight*. Dalam kasus ini terjadi pada percobaan cara kedua. Parameter yang membedakan dalam percobaan pada tahapan ini adalah jumlah *layer* model, bentuk model, dan jumlah parameter dari masing-masing node dalam model.

Tahapan *train* model merupakan tahapan yang penting. Dalam melakukan *train* dalam percobaan ini jumlah maksimal *epoch* yang digunakan adalah 100. Akan tetapi, untuk mencari perbedaan antar model maka dilakukan pemberhentian pada *training* ketika nilai akurasi *train* tidak mengalami kenaikan setelah 5 *epoch*. Jumlah batch size yang digunakan pada *train* adalah 15. Sehingga jumlah *iteration* pada 1 *epoch* sebanyak 93 kali. Maka dalam nilai akurasi pada 1 *epoch train* didapatkan dari rata-rata nilai akurasi 93 *iteration* hasil prediksi yang benar dari sesuai kelas data. Begitu juga pencarian nilai akurasi *validation* yang didapatkan dari 1 *epoch training*.

Tahap terakhir menyimpan model yang telah dilatih. Tahap ini dilakukan supaya model ini dapat diimplementasikan secara langsung untuk dapat memilah sampah setelah memasukkan gambar sampah yang akan dipilah. Dalam *library* keras model disimpan dalam format *.h5 file*. Selain model, data yang disimpan adalah arsitektur model yang menjelaskan nilai batch, data, dan *layer* dari model. Serta nilai *weight* model yang berisikan nilai *weight* dari masing-masing *layer*.

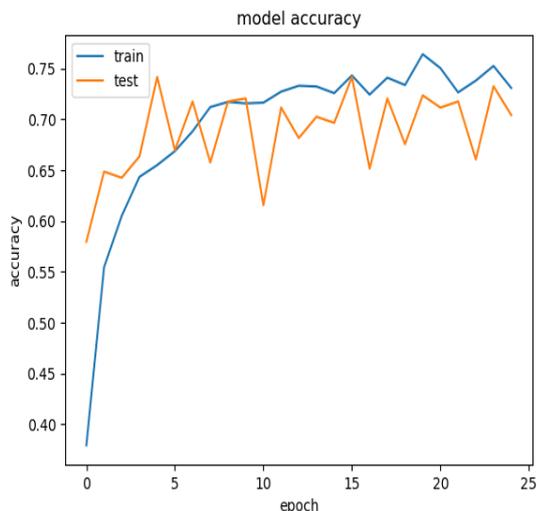
4. PEMBAHASAN DAN ANALISA

Hasil train model CNN

1. Mobilenet V1
 - a) Cara pertama

Tabel 1. Hasil *cross validation* cara pertama MobileNet

Cross Validation	Akurasi Training	Akurasi Validation	Jumlah epoch
1	0.69528	0.68836	25
2	0.67282	0.71208	19
3	0.69614	0.65817	23
4	0.68665	0.68128	25
5	0.67713	0.69083	20

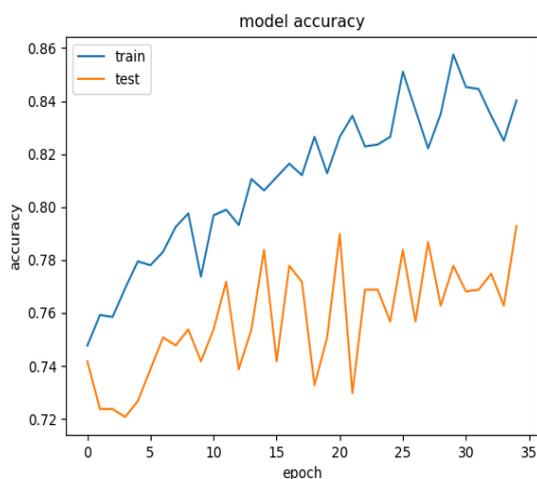


Gambar 2. Diagram akurasi cross validation 1 cara pertama MobileNet

b) *Cara kedua*

Tabel 2. Hasil *cross validation* cara kedua MobileNet

Cross Validation	Akurasi Training	Akurasi Validation	Jumlah epoch
1	0.80998	0.75699	35
2	0.78199	0.77257	14
3	0.77713	0.73719	9
4	0.76528	0.73169	13
5	0.78606	0.75714	18



Gambar 3. Diagram akurasi cross validation 1 cara kedua MobileNet

Tabel 1 dan 2 menunjukkan hasil *train* dari model mobilenet V1. Dalam melakukan *train* 1 *iteration* dalam 1 *epoch* membutuhkan waktu *train* sekitar 1 sampai 2 detik sehingga 1 *epoch* membutuhkan waktu selama 186 detik. Total waktu untuk

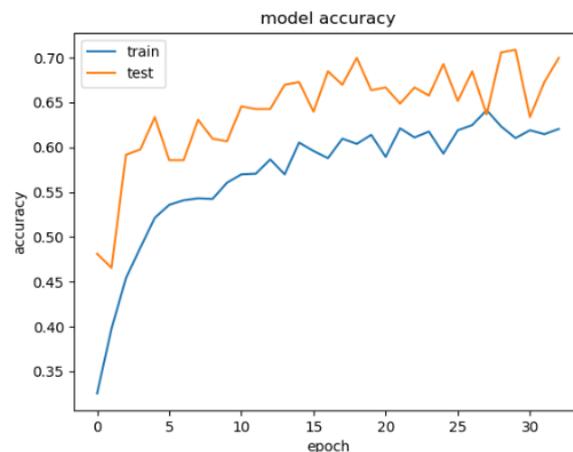
melakukan *train* satu kali *cross validation* pada cara pertama sekitar 73 menit. Sedangkan pada cara kedua membutuhkan waktu sekitar 145 menit untuk satu kali *cross validation*.

Jumlah parameter pada model ini sebanyak 3,232,964. Pada cara pertama jumlah parameter yang dilakukan *freeze* sebanyak 3,228,864 dan parameter dari *fully connect layer* sebanyak 4,100. Pada cara kedua jumlah parameter yang dilakukan *freeze* sebanyak 2,166,976 dan parameter yang dilakukan *unfreeze* pada model MobileNet ditambah *fully connect layer* sebanyak 1,065,988.

- 2) VGG 16
 - a) *Cara pertama*

Tabel 3. Hasil *cross validation* cara pertama VGG 16

Cross Validation	Akurasi Training	Akurasi Validation	Jumlah epoch
1	0.57048	0.64072	33
2	0.54712	0.63717	25
3	0.54013	0.54015	19
4	0.56851	0.61261	32
5	0.53767	0.56793	21

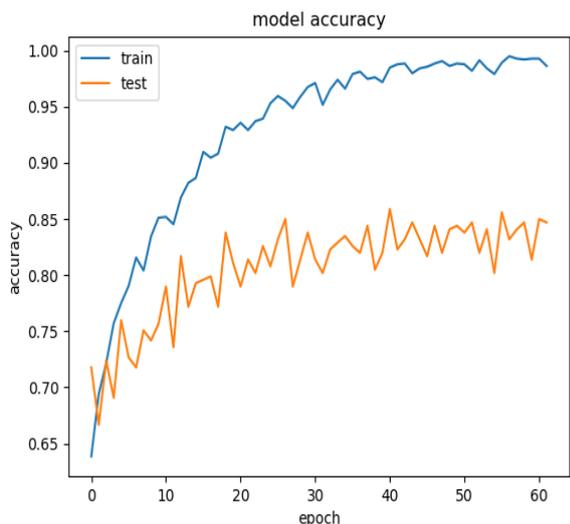


Gambar 4. Diagram akurasi cross validation 1 cara pertama VGG 16

b) *Cara kedua*

Tabel 4. Hasil *cross validation* cara kedua VGG 16

Cross Validation	Akurasi Training	Akurasi Validation	Jumlah epoch
1	0.92780	0.80553	62
2	0.90650	0.81497	46
3	0.89523	0.79078	42
4	0.93282	0.78633	65
5	0.91765	0.81434	51



Gambar 5. Diagram akurasi cross validation 1 cara kedua VGG 16

Tabel 3 dan 4 menunjukkan hasil *train* dari model VGG 16. Model ini memakan waktu sekitar 6 sampai 8 detik dalam 1 *iteration* sehingga 1 *epoch* membutuhkan sekitar 680 detik. Total waktu yang dibutuhkan model VGG 16 dalam melakukan *training* satu kali *cross validation* pada cara pertama sekitar 300 menit sedangkan pada cara kedua memakan waktu sekitar 921 menit.

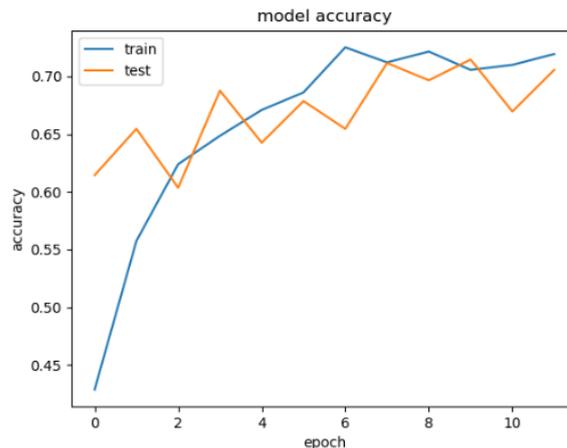
Parameter pada model ini berjumlah 14,716,740. Pada cara pertama jumlah parameter yang dilakukan *freeze* sebanyak 14,714,688 dan parameter yang *fully connect* yang dapat berubah sebanyak 2,052. Pada cara kedua jumlah parameter VGG 16 yang dilakukan *freeze* sebanyak 7,081,476 dan jumlah parameter yang dapat berubah sebanyak 7,635,264.

3) *Inception V3*

a) *Cara pertama*

Tabel 5. Hasil *cross validation* cara pertama Inception V3

Cross Validation	Akurasi Training	Akurasi Validation	Jumlah epoch
1	0.65919	0.66958	12
2	0.70670	0.68869	26
3	0.70482	0.65805	20
4	0.70391	0.66230	23
5	0.69377	0.71291	21

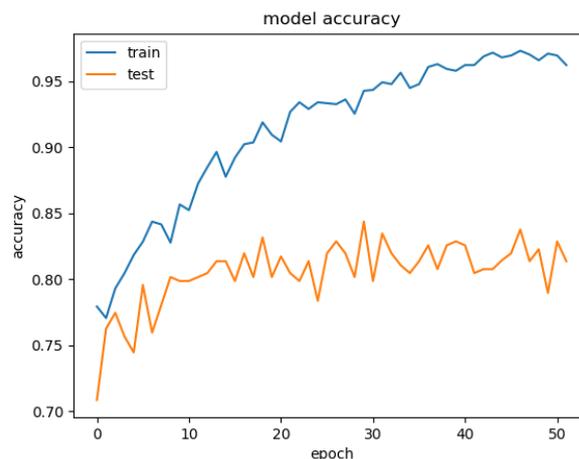


Gambar 6. Diagram akurasi cross validation 1 cara pertama Inception V3

b) *Cara kedua*

Tabel 6. Hasil *cross validation* cara kedua Inception V3

Cross Validation	Akurasi Training	Akurasi Validation	Jumlah epoch
1	0.91396	0.80506	52
2	0.87745	0.77512	30
3	0.88357	0.77655	31
4	0.87342	0.73706	28
5	0.92861	0.82095	65



Gambar 7. Diagram akurasi cross validation 1 cara kedua Inception V3

Tabel 5 dan 6 menunjukkan hasil *train* dari model Inception V3. Model ini memakan waktu sekitar 4 sampai 5 detik dalam 1 *iteration* sehingga 1 *epoch* membutuhkan waktu sekitar 465 detik. Total waktu yang dibutuhkan model Inception V3 dalam melakukan *training* satu kali *cross validation* pada cara pertama sekitar 172 menit sedangkan pada cara kedua memakan waktu sekitar 505 menit.

Jumlah parameter pada model ini sebanyak 21,810,980. Pada cara pertama parameter Inception V3 yang dilakukan *freeze* sebanyak 21,802,784 dan parameter yang dapat diubah pada *fully connect layer* sebanyak 8,196. Sedangkan cara kedua jumlah parameter yang dilakukan *freeze* sebanyak 15,729,248 dan parameter yang dapat diubah nilainya sebanyak 6,081,732

4) Resnet 50

a) Cara pertama

Tabel 7. Hasil *cross validation* cara pertama ResNet 50

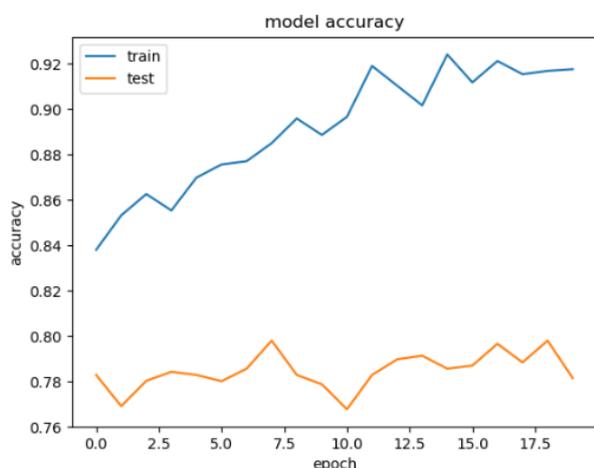
Cross Validation	Akurasi Training	Akurasi Validation	Jumlah epoch
1	0.7671	0.71025	15
2	0.7966	0.75742	29
3	0.79701	0.74197	26
4	0.77032	0.75901	16
5	0.79045	0.76592	25

Gambar 8. Diagram akurasi *cross validation* 1 cara pertama ResNet 50

b) Cara kedua

Tabel 8. Hasil *cross validation* cara kedua ResNet 50

Cross Validation	Akurasi Training	Akurasi Validation	Jumlah epoch
1	0.89185	0.78475	20
2	0.89968	0.81202	25
3	0.93162	0.79450	50
4	0.94006	0.80263	67
5	0.88587	0.81793	15



Gambar 9. Diagram akurasi *cross validation* 1 cara kedua ResNet 50

Tabel 7 dan 8 menunjukkan hasil *train* dari model Resnet 50. Model ini memakan waktu sekitar 5 sampai 6 detik dalam 1 *iteration* sehingga 1 *epoch* membutuhkan waktu sekitar 558 detik. Total waktu yang dibutuhkan model Resnet 50 dalam melakukan *training* satu kali *cross validation* pada cara pertama sekitar 215 menit sedangkan pada cara kedua memakan waktu sekitar 550 menit.

Jumlah parameter pada model ini adalah 23,595,908. Pada cara pertama jumlah parameter yang dilakukan *freeze* sebanyak 23,587,712 dan parameter pada *fully connect layer* sebanyak 8,196. Sedangkan pada cara kedua jumlah parameter model Resnet 50 yang dilakukan *freeze* sebanyak 19,122,048 dan total parameter dari *layer* terakhir Resnet 50 ditambah *fully connect layer* yang dapat diubah sebanyak 4,473,860.

B. Pembahasan Model Terbaik

Tabel 9. Perbandingan akurasi *train* model cara pertama

ACC	1	2	3	4	5	average
Resnet	0.7671	0.7966	0.79701	0.77032	0.79045	0.7843
VGG	0.5705	0.5471	0.5401	0.5685	0.5375	0.5528
Inception	0.6592	0.7067	0.7048	0.7039	0.6938	0.69368
mobilenet	0.6953	0.6728	0.6961	0.6867	0.6771	0.6856

Tabel 10. Perbandingan akurasi *validation* model cara pertama

VALA CC	1	2	3	4	5	average
Resnet	0.7103	0.7574	0.7402	0.7526	0.7679	0.74691
VGG	0.6407	0.6372	0.5402	0.6126	0.5679	0.59972
Inception	0.6696	0.6887	0.6581	0.6623	0.7129	0.67831
mobilenet	0.6884	0.7121	0.6582	0.6813	0.6908	0.68614

Berdasarkan hasil pengujian tabel 9 dan 10 dapat dikatakan pada cara pertama Resnet 50 merupakan salah satu model dengan performa yang paling baik yaitu memiliki akurasi sekitar 75%. Mobilenet merupakan model dengan performa kedua paling baik.

Tabel 11. Perbandingan akurasi *train* model cara kedua

ACC	1	2	3	4	5	average
Resnet	0.89	0.89	0.93	0.94	0.88	0.909
VGG	0.92	0.90	0.89	0.93	0.91	0.916
Inception	0.91	0.87	0.88	0.87	0.92	0.895
mobile		0.78	0.77	0.76	0.78	0.784
net	0.81	2	71	53	61	09

Tabel 12. Perbandingan akurasi *validation* model cara pertama

VALA CC	1	2	3	4	5	average
Resnet	0.78	0.81	0.79	0.80	0.81	0.802
VGG	0.80	0.81	0.79	0.78	0.81	0.802
Inception	0.80	0.77	0.77	0.73	0.82	0.782
mobile	0.75	0.77	0.73	0.73	0.75	0.751
net	7	26	72	17	71	12

Berdasarkan hasil tabel 11 dan 12 VGG 16 memiliki performa yang paling baik pada cara kedua. Model Resnet 50 dalam cara kedua merupakan model dengan performa kedua paling baik. Selain itu, berdasarkan hasil tabel 9,10,11, dan 12 dapat dikatakan bahwa semua model mengalami peningkatan akurasi baik *train* maupun *validation* dari cara pertama menjadi cara kedua. Maka peningkatan jumlah parameter dan optimasi nilai *weight* dapat meningkatkan performa dari *transfer learning* model CNN.

Dari kedua cara di atas model Mobilenet V1 memiliki nilai akurasi antara *train* dan *validation* yang paling mendekati satu dengan yang lain karena model ini memiliki kompleksitas yang paling kecil diantara semua model. Hal ini dibuktikan dengan jumlah parameter pada model ini paling sedikit dan waktu *train* model ini paling cepat diantara keempat model. Hal ini dapat terjadi karena perbedaan pada model ini menggunakan *depthwise convolutional Filter*. Filter ini memiliki perbedaan dalam pembagian channel dengan filter pada umumnya. Pada umumnya filter CNN memiliki ukuran channel yang besar seperti 64, 128, 512, dan lain-lain. Akan tetapi, pada cara ini terjadi pemisahan sehingga mengurangi kompleksitas dari persamaan (1)

$$D_K^2 * M * N * D_F^2$$

Menjadi persamaan (2)

$$D_K^2 * M * D_F^2 + M * N * D_F^2$$

Dengan D_K = ukuran kernel, M = jumlah *input channel*, N = Jumlah *output channel*, dan D_F = ukuran *feature map*. Sehingga mengurangi komputasi dan kompleksitas kurang dari 8 sampai 9 kali CNN biasa [18].

Model VGG 16 pada hasil yang didapat mengalami peningkatan yang paling besar dari cara pertama ke cara kedua. Hal ini dapat terjadi karena terjadi peningkatan yang paling jauh dari parameter yang dapat diubah. Kenaikan ini terjadi sebanyak kurang lebih 5 juta parameter. Akan tetapi pada model VGG 16 masih memiliki kelemahan paling besar dari semua model yaitu memiliki waktu *train* paling lama dibandingkan model-model lain. Hal ini karena VGG 16 masih tergolong dari model *classic CNN* yang memiliki bentuk *layer* sama pada CNN seperti umumnya. *Convolutional layer* pada VGG 16 memiliki nilai filter yang besar sehingga untuk mencapai nilai akurasi tinggi atau berhenti *train* membutuhkan jumlah *epoch* yang paling banyak dibandingkan keempat model. Selain itu, kenaikan antar satu *epoch* ke *epoch* selanjutnya, VGG memiliki kenaikan yang kecil atau stabil maka jumlah *epoch* yang digunakan banyak.

Sedangkan model Inception V3 dari cara pertama dan kedua memiliki rata-rata akurasi total ketiga paling baik setelah MobileNet. Dari keempat model, model ini memiliki jumlah *convolutional layer* paling banyak. Pada satu inception memiliki 6 *convolutional layer*. Akan tetapi, dari 6 *convolutional layer* hanya terhitung dua *layer* yang tidak parallel dan memiliki nilai *weight* satu inception memiliki dua *layer*. Maka dari jumlah *layer* dan parameter Inception V3 pada percobaan ini merupakan model yang menengah baik percobaan satu maupun kedua.

Model Resnet 50 memiliki jumlah *layer* dan parameter yang paling banyak dari semua model yang ada. Oleh sebab itu, walaupun jumlah parameter yang dapat berubah memiliki jumlah yang sama seperti Inception V3 percobaan pertama hasil performa yang didapatkan lebih baik. Selain itu, pada model Resnet terdapat *identity* yang dapat mengirimkan informasi hasil dari satu *layer* menuju langsung dua *layer* setelahnya. Hal ini dilakukan untuk dapat mengurangi *layer* yang menghasilkan *output* parameter salah atau tidak sesuai dengan fitur gambar. Maka walaupun jumlah parameter yang dapat berubah pada cara kedua tidak sebanyak VGG 16 tetap mendapatkan nilai akurasi yang berbeda kurang dari 1%.

5. KESIMPULAN

Berdasarkan hasil pengujian dan Analisa dapat disimpulkan dengan menggunakan *transfer learning* cara pertama atau tanpa ada perubahan maka model

Resnet 50 merupakan pilihan yang paling baik dari segi performa. Sedangkan pada cara kedua menggunakan model VGG 16. Akan tetapi, apabila melihat dari segi waktu, jumlah *epoch*, dan param. Model Resnet 50 masih memiliki performa yang lebih baik dibandingkan dengan VGG 16. Maka untuk mendapatkan hasil yang baik dengan menggunakan cara kedua digunakan Resnet 50.

Untuk penerapan model pada tempat sampah secara langsung dapat menggunakan model MobileNet karena model ini memiliki kompleksitas paling kecil dan waktu *train* yang paling cepat. Sehingga model ini sangat sesuai apabila menggunakan perangkat seperti Raspberry Pi sebagai kontrol dari tempat sampah. Apabila penerapan tempat sampah menggunakan jaringan atau server untuk melakukan prediksi maka dapat menggunakan model Resnet 50.

Perkembangan penelitian ini dapat dilakukan dengan mencoba mengubah data menjadi kelas yang lebih banyak sebagai contoh sampah plastik yang masih dapat dibagi menjadi botol plastik, tempat makan plastik, dan kantong plastik. Hal ini dapat dilakukan untuk meningkatkan akurasi karena proses *train* gambar yang lebih detail dan memiliki bentuk yang hampir sama antar kelas. Selain itu, dapat dilakukan penambahan data lebih banyak seperti satu kelas 1000 data.

ACKNOWLEDGMENT

Ucapkan terima kasih disampaikan kepada Bapak Handri Santoso, Dr. Eng selaku dosen pembimbing yang membantu dalam memberikan saran dan pendapat untuk dapat menyempurnakan penelitian ini.

DAFTAR PUSTAKA

- [1] P. B. C. K. Daniel Hoornweg, "Environment: Waste production must peak this century," *Nature International Weekly Journal of Science*, 30 October 2013.
- [2] United States Environmental Protection Agency, "Municipal Solid Waste Generation, Recycling, and Disposal in the United States: Facts and Figures for 2012," United States, 2012.
- [3] The University of Edinburgh, "Chapter 11 Waste Diposal," Edinburgh.
- [4] S. Puspita, "Indonesia Penyumbang Sampah Plastik Terbesar Kedua di Dunia," *Kompas.com*, 19 August 2018.
- [5] "HEADLINE: Sampah Plastik Indonesia Juara 2 Dunia, Bagaimana Mengatasinya?," *Liputan 6*, 28 November 2018.
- [6] CNN Indonesia, "Riset: 24 Persen Sampah di Indonesia Masih Tak Terkelola," *CNN Indonesia*, 25 april 2018.
- [7] Eco-Cycle, "Why Recycle".
- [8] Oregon State University, "Chapter Four Recycling Processes," Oregon State University, Oregon, 2018.
- [9] G. S. Linda Shapiro, "Chapter 1 Introduction," dalam *Computer Vision*, Seattle, 2000, pp. 13-30.
- [10] P. Randall B. Smith, *Image Classification*, Lincoln, 2011.
- [11] R. K. a. C. R. Samer Hijazi, "Using Convolutional Neural Networks for Image Recognition," 2015.
- [12] K. T. O'Shea, "An Introduction to Convolutional Neural Networks," *ResearchGate*, Penglais, 2015.
- [13] A. Deshpande, "The 9 Deep Learning Papers You Need To Know About (Understanding CNNs Part 3)," 24 August 2016.
- [14] C. o. T. f. R. Status, "Mindy Yang, Gary Thung," California, 2016.
- [15] O. R. O. L. F. S. L. E. G. Andres Torres, "Intelligent Waste Separator," Mexico, 2015.
- [16] E. A. S. Alexandre Fieno Silva, "Artificial Intelligence in Automated Sorting in Trash Recycling," *ResearchGate*, São Paulo, 2018.
- [17] A. v. K. A. D. F. N. O. H. K. E. J.-P. T. Mohammad Saeed Rad, "A Computer Vision System to Localize and Classify Wastes on the Streets," *Cornell University*, 2017.
- [18] M. E. C. N. N. f. M. VisionApplications, "Andrew G. Howard, Menglong Zhu, Bo Chen, Dmitry Kalenichenko, Weijun Wang, Tobias Weyand, Marco Andreetto, Hartwig Adam," 2017.

PEDOMAN PENULISAN

1. Naskah belum pernah dipublikasikan atau dalam proses penyuntingan dalam jurnal ilmiah atau dalam media cetak lain.
2. Naskah diketik dengan spasi 1 pada kertas ukuran A4 dan spasi 2,5 sentimeter dengan huruf *Times New Roman* berukuran 11 point. Naskah diserahkan dalam bentuk cetakan sebanyak 2 eksemplar disertai *file* dalam CD atau dapat dikirim melalui *e-mail* kepada redaksi.
3. Naskah bebas dari tindakan plagiat.
4. Naskah dapat ditulis dalam bahasa Indonesia atau bahasa Inggris dengan jumlah isi 10–25 halaman A4 termasuk daftar pustaka.
5. Naskah berupa artikel hasil penelitian terdiri dari komponen: judul, nama penulis, abstrak, kata kunci, pendahuluan, metode, hasil, pembahasan, kesimpulan, daftar pustaka.
6. Daftar pustaka terdiri dari acuan primer (80%) dan sekunder (20%). Acuan primer berupa jurnal ilmiah nasional dan internasional, sedangkan acuan sekunder berupa buku teks.
7. Naskah berupa artikel konseptual terdiri dari komponen: judul, nama penulis, abstrak, kata kunci, pendahuluan, hasil, pembahasan, kesimpulan, daftar pustaka, dan ucapan terima kasih (jika ada).
8. Judul harus menggambarkan isi artikel secara lengkap, maksimal terdiri atas 12 kata dalam bahasa Indonesia atau 10 kata dalam bahasa Inggris.
9. Nama penulis disertai dengan asal lembaga tetapi tidak disertai dengan gelar. Penulis wajib menyertakan biodata penulis yang ditulis pada lembar terpisah, terdiri dari: alamat kantor, alamat, dan telepon rumah, Hp. dan *e-mail*.
10. Abstrak ditulis dalam bahasa Inggris atau bahasa Indonesia. Abstrak memuat ringkasan esensi hasil kajian secara keseluruhan secara singkat dan padat. Abstrak memuat latar belakang, tujuan, metode, hasil, dan kesimpulan. Abstrak diketik spasi tunggal dan ditulis dalam satu paragraf.
11. Kata kunci harus mencerminkan konsep atau variabel penelitian yang dikandung, terdiri atas 5–6 kata.
12. Pendahuluan menjelaskan hal-hal pokok yang dibahas, yang berisi tentang permasalahan penelitian, tujuan penelitian, dan rangkuman kajian teoritik yang relevan. Penyajian pendahuluan dalam artikel tidak mencantumkan judul.
13. Metode meliputi rancangan penelitian, populasi dan sampel, pengembangan instrumen penelitian, teknik pengumpulan data, dan teknik analisis data, yang diuraikan secara singkat.
14. Hasil menyajikan hasil analisis data yang sudah final bukan data mentah yang belum diolah.
15. Pembahasan merupakan penegasan secara eksplisit tentang interpretasi hasil analisis data, mengaitkan hasil temuan dengan teori atau penelitian terdahulu, serta implikasi hasil temuan dikaitkan dengan keadaan saat ini.
16. Pemaparan deskripsi dapat dilengkapi dengan gambar, foto, tabel, dan grafik yang semuanya mencantumkan judul, dan sumber acuan jika diperlukan.
17. Istilah dalam bahasa Inggris ditulis dalam huruf miring (*italic*).

Redaksi :
Pusat Studi Teknologi Informasi - Fakultas Ilmu Komputer
Universitas Bandar Lampung
Gedung M Lantai 2 Pascasarjana
Jl.Zainal Abidin Pagar Alam no.89 Gedong Meneng Bandar Lampung
Email: explore@ubl.ac.id

