

# Analisis Citra Pada Potret Botol Minuman Bekas Menggunakan Algoritma *Convolutional Neural Network*

Nandiko Ramadhani<sup>1\*</sup>, Zendi Iklima<sup>1</sup>

<sup>1</sup>Teknik Elektro, Universitas Mercu Buana, Jakarta

\*nandikoramadhanitugas@gmail.com

**Abstrak**— Hadirnya kehidupan manusia yang menggunakan berbagai jenis produk berpotensi menghasilkan beraneka ragam sampah. Dalam situs resmi Sistem Informasi Pengelolaan Sampah Nasional (SIPSN), urutan kedua pada produksi sampah nasional tahun 2021 adalah sampah plastik. Sampah botol minuman bekas berbahan dasar plastik membutuhkan waktu yang lama agar dapat terurai. Di antara solusinya ialah dengan melakukan daur ulang sampah. Sebagian pengelola daur ulang masih menggunakan teknik penyortiran sampah secara manual, sehingga dibutuhkan sistem klasifikasi agar mempermudah penyortiran sampah botol minuman bekas. Pada penelitian ini, dilakukan perancangan sistem dengan algoritma *Convolutional Neural Network* (CNN), di mana terdapat beberapa model CNN tunggal dengan *base model* dari *MobileNetV2* dan dimodifikasi pada bagian *head model* atau *fully-connected layer*, sehingga menghasilkan arsitektur *MobileNetV2* dengan tiga macam *head model*, yaitu *Head Model 1*, *Head Model 2*, dan *Head Model 3*. Selain itu, diusulkan metode *ensemble* yang diterapkan pada seluruh model CNN tunggal dengan mengambil nilai bobot (*weight*) yang diperoleh setelah pelatihan, kemudian dilakukan proses bobot rata-rata (*average weights*) untuk meningkatkan performa pengklasifikasian gambar. Bentuk model baru ini dikenal dengan *Ensemble Convolutional Neural Network* (E-CNN). Berdasarkan hasil pengujian yang dilakukan, model CNN mampu mengklasifikasikan citra pada potret botol minuman bekas secara akurat dan efektif. Hal ini ditunjukkan pada nilai *classification report* pengujian, yaitu penggunaan model CNN tunggal berupa arsitektur *MobileNetV2* dengan *Head Model 1*, *Head Model 2*, dan *Head Model 3* memiliki nilai *accuracy* berturut-turut sebesar 91%, 89%, dan 91%. Selain itu, setelah diterapkan metode *ensemble* dan menjadi model E-CNN, maka didapatkan nilai *accuracy* pengujian sebesar 98%, di mana terjadi peningkatan nilai *accuracy* sebesar 7% hingga 9%.

**Kata Kunci**— Botol minuman bekas, *Convolutional Neural Network* (CNN), *Ensemble method*, *Klasifikasi citra*, *MobileNetV2*

DOI: 10.22441/jte.2024.v15i3.003

## I. PENDAHULUAN

Sampah merupakan di antara bentuk persoalan yang patut diperhatikan dan dihadapi. Hadirnya kehidupan manusia yang menggunakan berbagai jenis produk yang tersedia saat ini berpotensi menghasilkan beraneka ragam sampah, baik sampah rumah tangga, perniagaan, perkantoran, dan berbagai sektor lainnya. Pertumbuhan populasi manusia akan berbanding lurus dengan peningkatan kebutuhan sehari-hari, serta berakibat pada peningkatan produksi sampah [1]. Pada situs resmi Sistem Informasi Pengelolaan Sampah Nasional (SIPSN) yang berada dalam naungan Kementerian Lingkungan Hidup dan Kehutanan

(KLHK), menjelaskan tentang Capaian Kinerja Pengelolaan Sampah. Total produksi sampah nasional tahun 2021 yang terdiri dari 234 kabupaten atau kota se-Indonesia telah mencapai 29.565.740 ton per tahun. Sumber sampah nasional berasal dari berbagai sektor, di antaranya rumah tangga menduduki posisi pertama dengan perolehan 40.88%, kemudian disusul oleh perniagaan dengan perolehan 18.08%. Berdasarkan jenisnya, sampah yang mendominasi pada produksi sampah nasional berasal dari sisa makanan dengan perolehan 40.72%. Sedangkan, sampah plastik berada di urutan kedua dengan perolehan 17.47% [2].

Pada umumnya, botol minuman terbuat dari bahan aluminium, *stainless steel*, kaca, dan plastik. Botol minuman plastik termasuk sampah anorganik. Sampah anorganik merupakan sampah yang sudah tidak digunakan kembali dan sulit terurai [3]. Sampah botol plastik tidak dapat sepenuhnya terurai, sebab membutuhkan waktu hingga ratusan tahun agar dapat terurai dan hal ini meninggalkan dampak negatif terhadap lingkungan [4]. Di antara solusi untuk mengatasi hal tersebut ialah dengan melakukan daur ulang sampah botol minuman bekas berbahan dasar plastik. Sebagian pengelola daur ulang masih menggunakan teknik penyortiran sampah secara manual [5], sehingga dibutuhkan suatu sistem klasifikasi agar mempermudah dalam penyortiran sampah botol minuman bekas tersebut. Di antara metode *Deep Learning* (DL) yang dapat menangani permasalahan ini ialah *Convolutional Neural Network* (CNN). Perkembangan minat terhadap *deep learning* membuat jaringan saraf konvolusi atau *convolutional neural network* menjadi sebuah alat yang paling sering digunakan untuk klasifikasi citra (*image classification*) dan analisis citra [6]. Melalui CNN ini, *feature* (ciri) dipelajari secara hierarkis dan mandiri. Pertama-tama, model akan mengidentifikasi *feature* tingkat awal, kemudian belajar mengenali dan menggabungkan *features* ini untuk mempelajari pola yang lebih rumit [7].

CNN mempunyai arsitektur yang bermacam-macam, seperti *LeNet*, *AlexNet*, *GoogleNet*, *ResNet*, dan sebagainya [8]. *MobileNet* merupakan salah satu arsitektur CNN yang didesain efektif, serta latensi rendah yang akan memudahkan dalam pengimplementasian sesuai kebutuhan *mobile* dan *embedded applications* [9]. *MobileNet* dibangun berdasar pada arsitektur sederhana dengan *Depthwise Separable Convolution* untuk membentuk *deep neural network* yang ringan komputasi [10]. Sedangkan, *MobileNetV2* merupakan pengembangan arsitektur yang berdasar pada model sebelumnya, yaitu *MobileNet* [11].

Pada penelitian ini, dilakukan klasifikasi citra pada potret botol minuman bekas berbahan dasar plastik dengan algoritma

CNN untuk membedakan antara merek botol satu dengan merek botol lainnya. Dalam penelitian ini, terdapat berbagai jenis model CNN tunggal dengan *base model* dari *MobileNetV2* yang akan dimodifikasi pada bagian *head model* atau *fully-connected layer*. Selain itu, dibentuk suatu model yang berasal dari penggabungan nilai bobot (*weight*) dari *output* pelatihan model CNN tunggal, sehingga model ini dikenal dengan istilah *Ensemble Convolutional Neural Network* (E-CNN).

## II. PENELITIAN TERKAIT

Penelitian yang dilakukan oleh Indraswari, *et al.* [12] menjelaskan tentang permasalahan analisis penyakit mata yang dilakukan secara manual oleh dokter pada citra fundus, sehingga hasil analisisnya bergantung pada pengalaman dan keahlian dari dokter tersebut. Oleh sebab itu, digunakan algoritma *Convolutional Neural Network* (CNN) untuk membantu para dokter dalam mendeteksi penyakit mata pada citra fundus tersebut. Arsitektur yang digunakan berupa *MobileNetV2* sebagai *base model*. Sedangkan, arsitektur *head model* yang diusulkan terdiri atas lapisan *global average pooling*, kemudian diikuti oleh 2 lapisan *fully-connected*. Pada penelitian ini menggunakan dataset citra fundus sebanyak 601 citra dan terbagi menjadi dua *class* besar, yaitu “normal” dan “abnormal”.

Pada penelitian Chatterjee, *et al.* [13] membahas tentang mendaur ulang botol plastik bekas merupakan langkah penting menuju perlindungan lingkungan dan pencemaran tanah. Botol plastik dari berbagai jenis biasanya memiliki nilai daur ulang yang bervariasi. Sebagian besar negara dalam mengategorikan sampah yang dapat didaur ulang masih secara manual. Oleh sebab itu, penelitian ini bertujuan untuk menyediakan sistem klasifikasi botol plastik transparan yang dapat didaur ulang secara otomatis dengan menggunakan dua arsitektur dari algoritma CNN dan dilakukan metode *ensemble* dengan memanfaatkan bobot *pre-trained InceptionV3* dan *Xception* sebagai inisialisasi untuk model baru yang dikenal dengan *IncepX-Ensemble*. Dalam penelitian ini, terdapat 6 *class* dengan total dataset sebanyak 4.200 citra, di mana jumlah citra tiap *class* sebanyak 700 citra.

Pada penelitian Oktaviana & Azhar [5] menjelaskan bahwasanya sampah menjadi polemik besar bagi kelangsungan lingkungan, masyarakat, dan ekonomi. Usaha pengelolaan sampah telah dilakukan, namun sebagian besar masyarakat belum dapat memilah sampah dengan benar. Oleh karena itu, pada penelitian ini dikembangkan algoritma CNN yang dapat menyortir 6 *class* sampah, antara lain *cardboard*, *plastic*, *paper*, *glass*, *metal*, dan *trash*. Arsitektur yang digunakan berupa *DenseNet169*. Kemudian, dilakukan penerapan metode *ensemble* pada lima model yang sudah dilakukan *oversampling* sebelumnya. Total dataset sebanyak 2.850 citra dengan jumlah citra tiap *class* sebanyak 475 citra.

Penelitian yang dilakukan oleh Ren, *et al.* [14] membahas tentang inspeksi visual sangat penting dalam operasi *maintenance*, *repair*, dan *overhaul* (MRO) pesawat. Pada proses tradisional, inspeksi visual dilakukan oleh operator manusia yang memakan waktu dan bersifat subjektif. Beberapa metode telah dikembangkan menggunakan *Convolutional Neural Network* (CNN) untuk mengklasifikasikan kerusakan

permukaan pesawat. Namun, metode ini sering bergantung pada model tunggal untuk pendeteksian dan rentan terhadap bias selama proses pelatihan. Oleh sebab itu, jurnal ini menyampaikan metodologi inspeksi otomatis menggunakan *Ensemble CNN* untuk mengklasifikasikan kerusakan atau kecacatan pada citra permukaan pesawat dengan mengusulkan tiga desain model *ensemble*, yaitu *Ensemble A* (3x *ResNet18*), *Ensemble B* (*ResNet18*, *ResNet34*, *ResNet50*), dan *Ensemble C* (*Resnet18*, *GoogleNet*, *VGG11\_bn*). Dalam penelitian ini, total dataset yang digunakan sebanyak 600 citra, di mana terdiri dari 300 citra cacat dan 300 citra non-cacat.

Penelitian yang dilakukan oleh Nugroho, *et al.* [15] membahas permasalahan sampah botol plastik perlu disortir berdasarkan mereknya untuk mengurangi polusi. Namun, saat ini proses penyortiran masih dikerjakan secara manual, sehingga membutuhkan waktu yang lama. Oleh sebab itu, penelitian ini memanfaatkan teknik pengolahan citra untuk mengklasifikasi beberapa merek dari botol plastik dengan algoritma *Multiclass Support Vector Machine* (SVM) dengan *kernel Radial Basis Function* (RBF) serta pendekatan *One vs All*. Dalam penelitian ini, terdapat 5 *class* dengan total dataset sebanyak 500 citra.

Pada penelitian Pratama, *et al.* [16] membahas perkara sampah dapat dituntaskan pada tingkat hulu apabila masyarakat melakukan gerakan 3R, yaitu *reduce*, *reuse*, dan *recycle*. Untuk memberikan pembinaan perihal sampah kepada masyarakat diperlukan peranan teknologi, salah satunya ialah *computer vision*. Pada penelitian ini, diterapkan tipe *unsupervised learning* dengan algoritma *Convolutional Neural Network* (CNN) untuk mengidentifikasi macam-macam sampah plastik (anorganik). Dalam penelitian ini, total dataset sebanyak 300 citra dengan distribusi dataset untuk pelatihan 80% dan untuk pengujian 20%.

Penelitian yang dilakukan oleh Nugroho, *et al.* [17] menjelaskan masalah penumpukan sampah botol plastik sudah tidak terkontrol, sedangkan botol plastik memerlukan waktu yang sangat lama agar bisa terurai. Di antara cara untuk mengurangi sampah botol plastik ialah daur ulang. Oleh sebab itu, dibuat suatu sistem untuk mendeteksi botol plastik menggunakan algoritma *Convolutional Neural Network* (CNN) dengan model *Faster-RCNN* berarsitektur *InceptionV2*. Terdapat 740 dataset citra yang terbagi ke dalam 5 *class* botol plastik dari berbagai label merek.

Pada penelitian Valentina, *et al.* [18] menjelaskan tentang sampah botol plastik dan kaleng bekas, yang di mana sampah tersebut tidak dapat diuraikan secara alami oleh bakteri dan memerlukan tempo yang panjang untuk menguraikannya. Sebelum dilakukan proses daur ulang, diperlukan pemilahan sampah. Namun, pemilahan tersebut masih dilakukan secara manual, sehingga membutuhkan tenaga yang besar dan waktu yang lama. Oleh sebab itu, pada penelitian ini digunakan metode *Convolutional Neural Network* (CNN) dengan *Activation function* yang digunakan berupa ELU. Sedangkan, jumlah *layer* adalah 4 *convolution layer*, 4 *max-pooling layer*, dan 3 *fully-connected layer*. Nilai *learning rate* yang digunakan adalah 0.00001, *dropout* 0.8, dan jumlah *epoch training* sebanyak 50 kali. Total dataset pada penelitian ini sebanyak 1.000 citra.

### III. METODOLOGI PENELITIAN

Pada bagian ini akan dijelaskan mengenai analisa dan strategi pemecahan masalah; spesifikasi perangkat penelitian; diagram alur penelitian; penentuan *class*; teknik pengumpulan dataset; diagram alur sistem; pengolahan dataset; perancangan, pelatihan, dan pengujian model CNN; serta dilakukannya *ensemble* model.

#### A. Analisa dan Strategi Pemecahan Masalah

Botol minuman bekas berbahan dasar plastik ialah salah satu benda buangan yang sudah tidak terpakai, sehingga menjadi salah satu sumber sampah nasional. Sampah botol plastik tidak dapat sepenuhnya terurai, sehingga diperlukan cara yang efektif untuk mencegah kerusakan lingkungan yang disebabkan oleh sampah botol plastik. Di antara solusi yang dapat dilakukan, yaitu dengan melakukan daur ulang sampah botol minuman bekas berbahan dasar plastik, yang di mana membutuhkan suatu sistem klasifikasi agar memudahkan dalam penyortiran sampah botol minuman bekas tersebut.

Di antara strategi pemecahan masalah tersebut ialah dengan menggunakan metode dari *deep learning* berupa algoritma CNN untuk mengklasifikasikan citra (gambar) sampah botol minuman bekas berbahan dasar plastik dari beberapa merek botol yang berbeda, serta diterapkan metode *ensemble* pada beberapa model CNN tunggal tersebut.

#### B. Spesifikasi Perangkat Penelitian

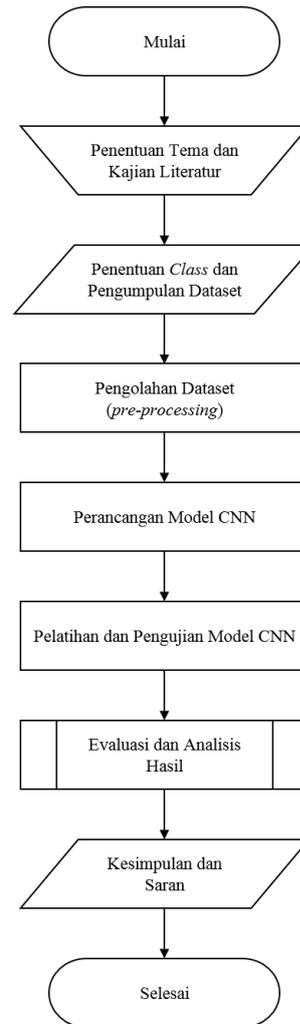
Perangkat yang digunakan pada penelitian ini ialah Google Colaboratory, yaitu layanan *coding environment* berbasis *cloud* Google dengan bahasa pemrograman Python 3. Google Colaboratory memiliki dua spesifikasi, yaitu spesifikasi pertama menggunakan pilihan Intel Xeon 2vCPU @2.2 GHz dengan kapasitas *disk* 107.72 GB dan RAM 12.68 GB. Kemudian, spesifikasi kedua menggunakan pilihan GPU NVIDIA Tesla T4 dengan kapasitas *disk* 166.77 GB dan RAM 25.45 GB. Penggunaan GPU memiliki kecepatan 39 hingga 77 kali lipat dibandingkan penggunaan CPU. Oleh karena itu, dalam penelitian ini menggunakan spesifikasi yang kedua, yaitu GPU NVIDIA Tesla T4.

#### C. Diagram Alur Penelitian

Tahapan yang dilakukan dalam penelitian ini, yaitu pertama-tama menentukan tema yang ingin diusulkan dalam penelitian. Setelah itu, dilakukan metode studi kepustakaan dari berbagai referensi jurnal, *website*, dan bentuk penulisan lainnya untuk mencari informasi yang berkaitan dengan penelitian ini. Kemudian, dilakukan penentuan *class* terlebih dahulu sebanyak 8 *class* dari beberapa merek botol minuman bekas. Setelah itu, dilakukan pengumpulan dataset berupa potret botol minuman bekas, serta mengolah (*pre-processing*) potret tersebut.

Selanjutnya ialah tahapan perancangan seluruh model CNN yang dilakukan pada Google Colaboratory. Kemudian, dilakukan pelatihan dan pengujian seluruh model CNN. Setelah itu, dilakukan evaluasi serta analisis hasil pelatihan dan pengujian dari seluruh model CNN untuk menentukan model yang terbaik dalam mengklasifikasikan citra (gambar) pada potret botol minuman bekas tersebut. Terakhir, dibuat suatu kesimpulan untuk menerangkan segala hal yang dianggap pokok

dalam penelitian ini. Adapun diagram alur penelitian disajikan pada Gambar 1.



Gambar 1. Diagram Alur Penelitian

#### D. Penentuan Class

Sebelum dilakukan pengumpulan dataset, maka dilakukan penentuan *class* terlebih dahulu. Pada penelitian ini ditentukan sebanyak 8 *class* dari beberapa merek botol minuman bekas, sebagaimana yang tertera pada Tabel 1.

Tabel 1. Penentuan Class

No.	Class	Keterangan
1.	merek_a	Botol minuman bekas merek Aqua
2.	merek_c	Botol minuman bekas merek Cleo
3.	merek_f	Botol minuman bekas merek Frestea
4.	merek_m	Botol minuman bekas merek LeMinerale
5.	merek_n	Botol minuman bekas merek Nestle
6.	merek_o	Botol minuman bekas merek Oasis
7.	merek_t	Botol minuman bekas merek Teh Pucuk
8.	merek_v	Botol minuman bekas merek Vit

### E. Teknik Pengumpulan Dataset

Data yang digunakan dalam penelitian ini adalah data primer. Data yang dikumpulkan berupa data citra (gambar) botol minuman bekas berbahan dasar plastik dengan logo segitiga berangka 1 atau kode PET (*polyethylene terephthalate*) yang dipotret dengan kamera *smartphone*, format citra .jpg, dan kualitas kamera 13 *Megapixel* (MP). Untuk menghindari ketidakseimbangan dataset (*imbalanced dataset*), maka pada proses pemotretan citra dilakukan generalisasi jumlah dataset sebesar 576 citra untuk setiap *class*, sehingga total dataset berjumlah 4.608 citra.

Pada proses pemotretan menggunakan latar belakang berwarna putih untuk mengurangi *noise* pada dataset citra. Kemudian, perbandingan rasio potret adalah 1 : 1 dengan resolusi dimensi potret sebesar 3.120 x 3.120 piksel. Setiap botol memiliki model pemotretan yang berbeda, sebagaimana contoh citra pada *class* merek\_f yang tertera pada Gambar 2.

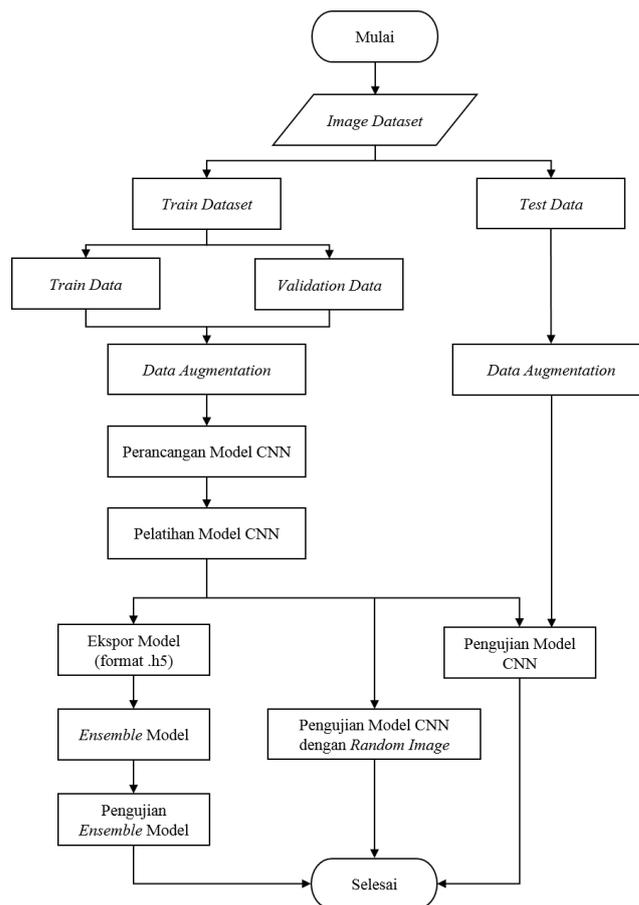


Gambar 2. Contoh Model Pemotretan

### F. Diagram Alur Sistem

Diagram alur sistem yang tertera pada Gambar 3 berfungsi untuk menerangkan cara kerja sistem secara sederhana dan mempermudah dalam peninjauan apabila terjadi *error*. Bagian pokok sistem pada penelitian ini, yaitu pemrosesan data, pelatihan (*training*) model, pengujian (*testing*) model, dan *ensemble* model. Pada mulanya, dilakukan pengimporan dataset citra yang diletakkan pada Google Drive ke dalam *notebook* Google Colaboratory. Selanjutnya, dilakukan pembagian dataset citra menjadi dua bagian terlebih dahulu, yaitu *train dataset* dan *test data*. Kemudian, dari *train dataset* akan dipecah kembali menjadi dua bagian, yaitu dataset untuk pelatihan berupa *train data* dan dataset untuk validasi berupa *validation data*. Selanjutnya, dilakukan proses *data augmentation* pada seluruh dataset untuk memperkaya ragam atau fitur dari citra.

Setelah itu, masuk pada tahap perancangan model CNN, di mana model tersebut akan digunakan pada tahap pelatihan. Pada tahap perancangan model, dibangun beberapa macam atau tipe *head model* yang berbeda-beda, akan tetapi berdasar pada *base model* yang sama, yaitu *MobileNetV2*. Selanjutnya, masuk pada proses pelatihan model CNN dengan menggunakan dataset yang telah dipersiapkan sebelumnya, yaitu *train data* dan juga *validation data*.



Gambar 3. Diagram Alur Sistem

Setelah dilakukan pelatihan model CNN, maka selanjutnya terdapat tiga proses yang akan dilakukan, yaitu melakukan pengujian model CNN dengan dataset *test data* yang sudah dipersiapkan sebelumnya; melakukan pengujian (khusus) model CNN tunggal dengan dataset baru berupa *random image* yang akan diimpor dari penyimpanan Google Drive; dan melakukan pengeksporan model CNN tunggal yang sudah dilatih ke dalam Google Drive dengan format berkas .h5. Nantinya berkas .h5 akan diimpor kembali ke dalam suatu *notebook* Google Colaboratory untuk dilakukan metode *ensemble* dari berbagai model CNN tunggal yang telah dibuat. Tahapan terakhir, yaitu dilakukan pengujian *ensemble* model.

### G. Pengolahan Dataset

Dataset dibagi dengan porsi *train size* sebesar 0.85 atau 85% dari total dataset, sehingga menghasilkan 3.916 citra untuk *train dataset* dan 692 citra untuk *test data*. Kemudian, dilakukan *validation split* dengan porsi sebesar 0.25 atau 25% dari total *train dataset*, sehingga menyebabkan terbaginya *train dataset* menjadi dua bagian, yaitu *train data* sebanyak 2.937 citra untuk proses pelatihan dan *validation data* (val data) sebanyak 979 citra untuk validasi dari proses pelatihan.

Langkah berikutnya ialah melakukan *data augmentation*. Pada proses *data augmentation*, seluruh dataset dikenakan proses ini untuk memperkaya variasi atau ragam dari *feature* citra, sehingga memudahkan arsitektur untuk lebih mengenali

dataset citra. Terdapat beberapa teknik yang digunakan, seperti *rescale* untuk merubah *range* pada *array* citra yang semulanya 0 - 255 menjadi 0 - 1. Selain itu, digunakan pula teknik *rotation*, *zoom*, dan *flip*. Selanjutnya, ukuran rasio dataset citra dirubah menjadi 224 x 224 piksel karena menyesuaikan dengan arsitektur yang digunakan, yaitu *MobileNetV2*. Kemudian, tipe *color mode* yang digunakan ialah *Red Green Blue* (RGB), di mana memiliki tiga *channel* (kanal).

#### H. Perancangan Model CNN

Pada penelitian ini, perancangan model CNN menggunakan *base model* berupa arsitektur *MobileNetV2* dengan kondisi bagian *layer.trainable* berisikan *False* atau dengan kata lain dibekukan (*frozen*). Dengan demikian, proses pelatihan hanya dilakukan pada *head model* yang bertugas untuk mengenali dan membedakan karakteristik antara satu *class* dengan *class* lainnya. Dalam penelitian ini hanya terdiri dari 8 *class* sebagai *output*, sehingga *output* neuron dari *head model* ini akan disesuaikan dengan jumlah *class* yang dibutuhkan.

Pada bagian *head model* atau disebut juga area *fully-connected layer* digunakan arsitektur pribadi sebanyak tiga model, sehingga pada akhirnya terdapat tiga macam rancangan model CNN tunggal sebagaimana yang tertera pada Gambar 4.

```
1 model = Sequential()
2 model.add(base_model)
3 model.add(Flatten())
4 model.add(Dense(1024, activation='relu'))
5 model.add(Dense(512, activation='relu'))
6 model.add(Dropout(0.5))
7 model.add(Dense(8, activation='softmax')) #softmax sigmoid
```

(a)

```
1 model = Sequential()
2 model.add(base_model)
3 model.add(Flatten())
4 model.add(Dense(1024, activation='relu'))
5 model.add(Dense(512, activation='relu'))
6 model.add(Dense(256, activation='relu'))
7 model.add(Dropout(0.5))
8 model.add(Dense(8, activation='softmax')) #softmax sigmoid
```

(b)

```
1 model = Sequential()
2 model.add(base_model)
3 model.add(Flatten())
4 model.add(Dense(1024, activation='relu'))
5 model.add(Dense(512, activation='relu'))
6 model.add(Dropout(0.5))
7 model.add(Dense(128, activation='relu'))
8 model.add(Dropout(0.5))
9 model.add(Dense(8, activation='softmax')) #softmax sigmoid
```

(c)

Gambar 4. Rancangan Arsitektur Pribadi (a) *Head Model 1* (b) *Head Model 2* (c) *Head Model 3*

Pada bagian *head model* digunakan *dropout regularization* sebesar 0.5 atau 50% secara acak pada neuron untuk menghindari *overfitting*. Di antara penyebab terjadinya *overfitting* ialah bobot (*weight*) di dalam unit neuron pada model CNN terlalu kompleks dan berlebih, sehingga menjadikan proses pelatihan yang berlebihan [18]. Oleh karena itu, *dropout regularization* akan menggeneralisasi data pada model CNN

tersebut. Kemudian, digunakan pula *activation function* ReLU untuk membuat piksel yang bernilai negatif atau kurang dari nol pada citra menjadi nilai nol. Sedangkan, apabila nilai piksel positif, maka akan tetap sesuai dengan nilai pikselnya itu sendiri [19]. Selain itu, terdapat *dense* terakhir berupa *output layer* dengan 8 neuron dan *activation function* berupa *softmax*. Umumnya, *softmax* diletakkan pada *output layer* atau *classification layer* dari *fully-connected layer* model CNN untuk memberikan nilai probabilitas suatu prediksi terhadap *class* yang tersedia [20].

#### I. Pelatihan Model CNN

Dalam penelitian ini, proses pelatihan model menggunakan *optimizer Adam* dengan nilai *learning rate* secara *default* 0.001. Algoritma optimisasi digunakan untuk pembaruan bobot (*weight*) jaringan atau disebut dengan proses *back-propagation* [12]. Selanjutnya ialah *loss function* berupa *cross-entropy* dengan jenis *categorical*. *Cross-entropy* digunakan untuk mengidentifikasi nilai *error* saat proses pelatihan model, sehingga model dapat memperbaiki *error* tersebut [20]. Kemudian, digunakan *metrics* dengan tipe *accuracy* untuk menghitung seberapa sering prediksi sama dengan label tiap *class*. Pelatihan model dijalankan dengan dataset *train data*, serta dilakukan validasi pada pelatihan model dengan dataset *validation data*. Untuk nilai *epochs* yang digunakan sebanyak 25 dan *batch size* berukuran 48.

#### J. Pengujian Model CNN

Pengujian model CNN dilakukan dengan dua cara, yang pertama menggunakan *test data* yang sudah dipersiapkan sebelumnya, dan yang kedua menggunakan *random image* yang akan diimpor dari folder *random test* pada Google Drive dengan total dataset sebanyak 256 citra, di mana tiap *class* memiliki 32 citra.

Pada pengujian pertama yang menggunakan *test data* sebagai bahan uji model, maka hasilnya dalam bentuk *confusion matrix*, kemudian terdapat nilai *accuracy*, *precision*, *recall*, dan *f1-score*. Pada bentuk *confusion matrix*, bagian kolom mewakili hasil kelas prediksi dari data, sedangkan bagian baris mewakili kelas aktual dari data [21]. Dari *confusion matrix*, diperoleh data nilai yang dibutuhkan oleh *classification report* untuk menghitung performa model, seperti nilai *accuracy*, *precision*, *recall*, dan *f1-score* [22].

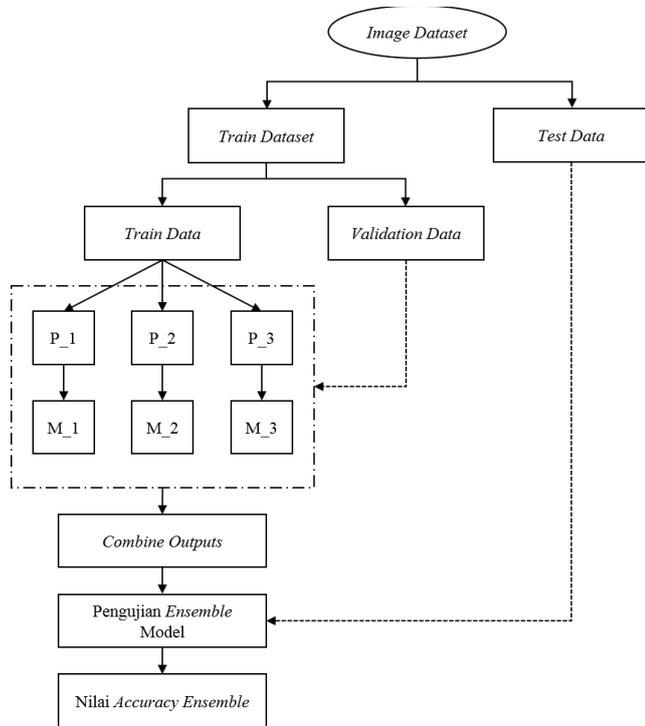
Pada pengujian kedua yang menggunakan *random image* sebagai bahan uji model, maka hasilnya terlihat dalam bentuk gambar botol beserta keterangannya, yaitu tertulis nilai probabilitas dari hasil prediksinya yang kemudian dijadikan sebagai nilai *argMax* sesuai indeks *class*, serta diberikan juga keterangan nama *class* dari gambar botol tersebut. Pengujian kedua ini dilakukan khusus atau hanya untuk model CNN tunggal agar dapat melihat hasil prediksi atau klasifikasi gambar tanpa dilakukan proses *data augmentation*, kecuali hanya *rescale*.

#### K. Ensemble Model

Pada dasarnya, metode *ensemble* mengacu kepada teknik penggunaan beberapa jenis model dengan jumlah model yang

tergantung pada kasus klasifikasi, kemudian menggabungkan hasil klasifikasi dari masing-masing model melalui sistem voting atau *average* sebagai hasil akhir klasifikasi [5].

Pada tahap ini, proses *ensemble* dilakukan pada tiga macam model CNN tunggal yang telah dirancang sebelumnya. Sebagaimana yang tertera pada Gambar 5, di mana  $P_n$  merupakan *proposed model* dan  $M_n$  merupakan *output model* berupa berkas .h5. Ketiga model CNN ini akan diambil nilai bobot (*weight*) yang diperoleh setelah pelatihan dan dilakukan proses *ensemble* dengan sistem bobot rata-rata (*average weights*) untuk meningkatkan *accuracy* pada klasifikasi citra.



Gambar 5. Rancangan Arsitektur *Ensemble Model*

Setelah proses *ensemble*, maka dilakukan suatu pengujian pada model *ensemble* atau E-CNN ini dengan dataset *test data*, sebagaimana pengujian yang dilakukan sebelumnya pada model CNN tunggal. Hal ini berguna untuk melihat kinerja pengklasifikasian pada model E-CNN dalam bentuk *confusion matrix*, serta terdapat *classification report* berupa *accuracy*, *precision*, *recall*, dan *f1-score*.

#### IV. HASIL DAN ANALISA

Pada bagian ini akan dijelaskan hasil pelatihan model CNN tunggal dari arsitektur *MobileNetV2* dengan tipe *Head Model 1*, *Head Model 2*, dan *Head Model 3*. Kemudian, dilakukan pengujian model CNN tunggal dengan dataset *test data*, dan dilakukan pula pengujian model CNN tunggal dengan dataset *random image*. Selain itu, menampilkan hasil pengujian dari *ensemble model* dengan dataset *test data* dan komparasi *classification report* dari seluruh model.

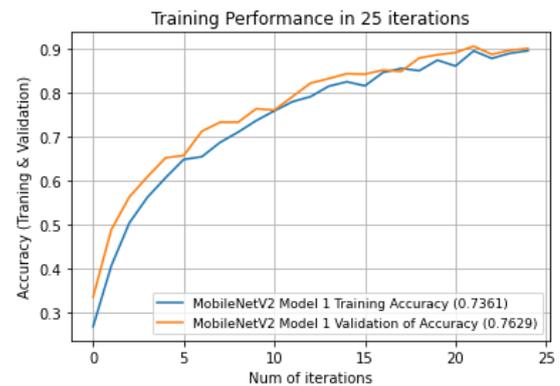
#### A. Pelatihan Model CNN Tunggal

Pelatihan arsitektur *MobileNetV2* dengan tipe *Head Model 1* berdurasi selama 4 jam 9 menit 57 detik untuk menjalankan 25 *epoch*. Hasil pelatihan dengan tipe *Head Model 1* dapat dilihat pada Tabel 2, di mana berisi nilai *loss* dan *accuracy* per 2 *epoch* pada proses pelatihan dan validasi.

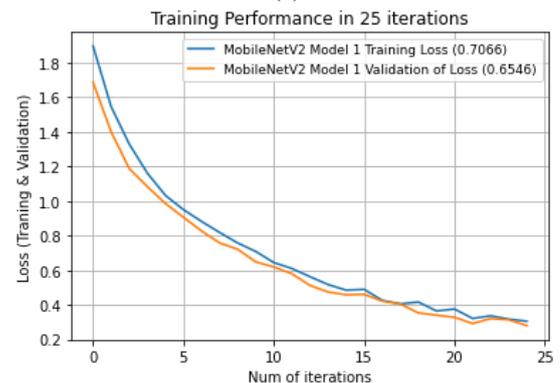
Tabel 2. Hasil Pelatihan Tipe *Head Model 1*

Epoch	Pelatihan		Validasi	
	Loss	Accuracy	Loss	Accuracy
1	1.8961	0.2686	1.6859	0.3361
3	1.3299	0.5039	1.1879	0.5628
5	1.0333	0.6064	0.9863	0.6517
7	0.8825	0.6541	0.8275	0.7120
9	0.7580	0.7099	0.7215	0.7324
11	0.6447	0.7583	0.6191	0.7600
13	0.5628	0.7906	0.5125	0.8212
15	0.4852	0.8243	0.4584	0.8427
17	0.4260	0.8454	0.4216	0.8509
19	0.4164	0.8495	0.3532	0.8784
21	0.3758	0.8601	0.3278	0.8907
23	0.3367	0.8774	0.3207	0.8866
25	0.3052	0.8948	0.2795	0.8999

Pada Gambar 6, ditampilkan grafik dari tipe *Head Model 1*, yaitu antara proses pelatihan dan proses validasi.



(a)



(b)

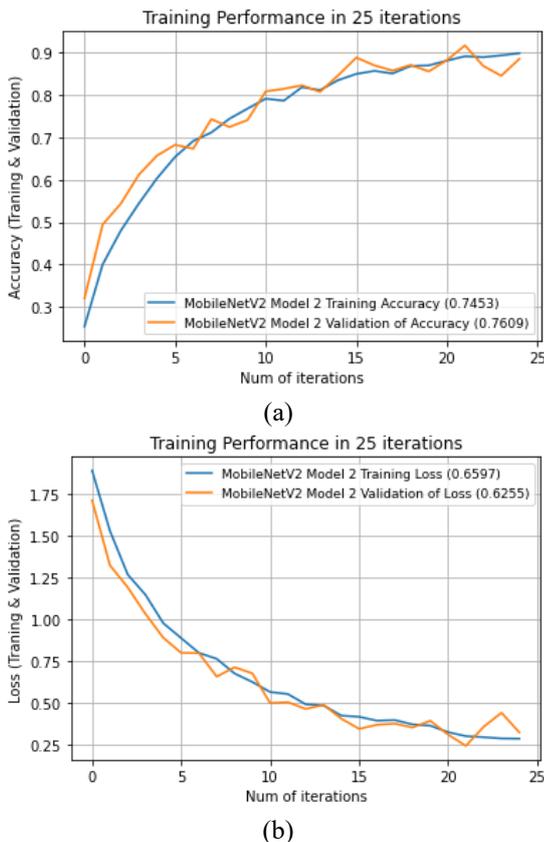
Gambar 6. Perbandingan Proses Pelatihan dan Validasi Tipe *Head Model 1* (a) *Accuracy* (b) *Loss*

Pelatihan arsitektur *MobileNetV2* dengan tipe *Head Model 2* berdurasi selama 4 jam 8 menit 32 detik untuk menjalankan 25 *epoch*. Hasil pelatihan dengan tipe *Head Model 2* dapat dilihat pada Tabel 3, di mana berisi nilai *loss* dan *accuracy* per 2 *epoch* pada proses pelatihan dan validasi.

Tabel 3. Hasil Pelatihan Tipe *Head Model 2*

Epoch	Pelatihan		Validasi	
	Loss	Accuracy	Loss	Accuracy
1	1.8913	0.2547	1.7128	0.3207
3	1.2682	0.4797	1.1915	0.5434
5	0.9764	0.6033	0.8890	0.6568
7	0.7985	0.6912	0.7968	0.6731
9	0.6751	0.7436	0.7122	0.7242
11	0.5640	0.7909	0.4978	0.8080
13	0.4902	0.8178	0.4621	0.8223
15	0.4225	0.8345	0.4039	0.8458
17	0.3922	0.8563	0.3673	0.8693
19	0.3698	0.8679	0.3512	0.8703
21	0.3233	0.8805	0.3082	0.8815
23	0.2931	0.8887	0.3559	0.8682
25	0.2843	0.8979	0.3218	0.8846

Pada Gambar 7, ditampilkan grafik dari tipe *Head Model 2*, yaitu antara proses pelatihan dan proses validasi.



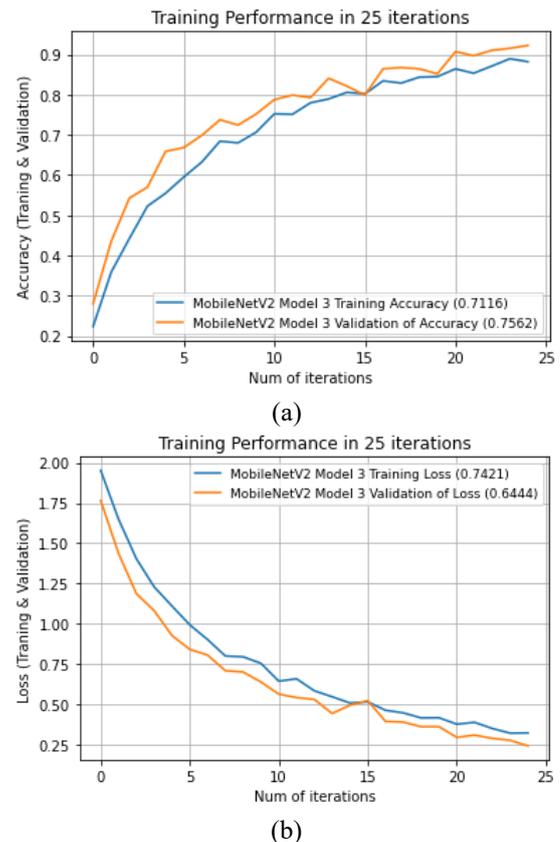
Gambar 7. Perbandingan Proses Pelatihan dan Validasi Tipe *Head Model 2* (a) Accuracy (b) Loss

Pelatihan arsitektur *MobileNetV2* dengan tipe *Head Model 3* berdurasi selama 4 jam 8 menit 14 detik untuk menjalankan 25 *epoch*. Hasil pelatihan dengan tipe *Head Model 3* dapat dilihat pada Tabel 4, di mana berisi nilai *loss* dan *accuracy* per 2 *epoch* pada proses pelatihan dan validasi.

Tabel 4. Hasil Pelatihan Tipe *Head Model 3*

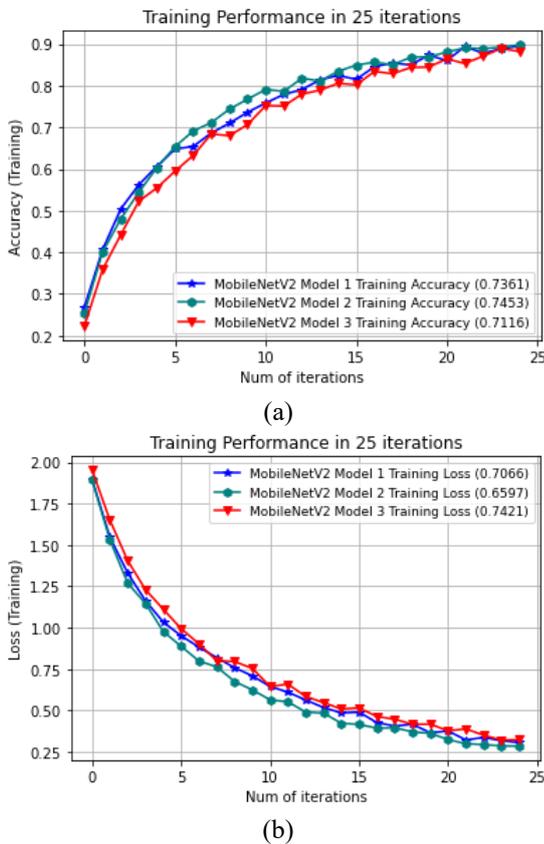
Epoch	Pelatihan		Validasi	
	Loss	Accuracy	Loss	Accuracy
1	1.9517	0.2234	1.7652	0.2799
3	1.4044	0.4419	1.1876	0.5424
5	1.1109	0.5546	0.9275	0.6588
7	0.9026	0.6323	0.8062	0.6987
9	0.7951	0.6799	0.7010	0.7242
11	0.6439	0.7521	0.5635	0.7875
13	0.5841	0.7797	0.5310	0.7926
15	0.5084	0.8056	0.4942	0.8212
17	0.4633	0.8342	0.3941	0.8641
19	0.4159	0.8434	0.3613	0.8641
21	0.3770	0.8641	0.2951	0.9070
23	0.3502	0.8710	0.2892	0.9101
25	0.3225	0.8819	0.2424	0.9224

Pada Gambar 8, ditampilkan grafik dari tipe *Head Model 3*, yaitu antara proses pelatihan dan proses validasi.



Gambar 8. Perbandingan Proses Pelatihan dan Validasi Tipe *Head Model 3* (a) Accuracy (b) Loss

Hasil pelatihan dari berbagai model CNN tunggal dengan tipe *head model* yang berbeda dapat digabungkan ke dalam satu bentuk plot grafik. Kemudian, dapat digunakan untuk merepresentasikan dan membandingkan nilai dari setiap model tersebut, sebagaimana yang tertera pada Gambar 9.



Gambar 9. Perbandingan Nilai Pelatihan dari Berbagai Tipe *Head Model* (a) *Accuracy* (b) *Loss*

Dari bentuk alur kurva pada Gambar 9, dapat dikatakan bahwa peningkatan nilai *accuracy* dan juga penurunan nilai *loss* berbanding lurus dengan bertambahnya jumlah *epoch*. Selain itu, dapat dikatakan bahwa tidak terjadi perubahan yang signifikan antara tipe *Head Model* 1, *Head Model* 2, dan *Head Model* 3, sehingga bentuk kurva atau celah antar kurva dari tiap model terlihat saling beriringan atau berimpitan antara satu dengan lainnya.

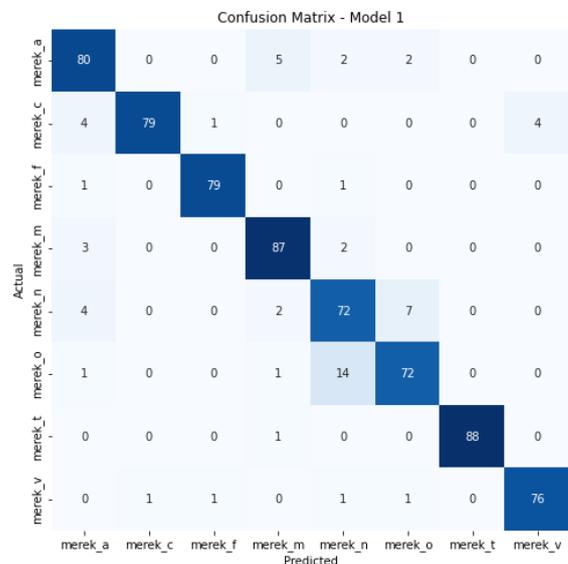
**B. Pengujian Model CNN Tunggal dengan Test Data**

Pada pengujian model CNN tunggal dengan dataset *test data*, data telah dibagi sebelumnya dalam proses pengolahan dataset sebanyak 692 citra dari berbagai *class*. Adapun distribusi dataset *test data* dalam pengujian kali ini terdapat pada Tabel 5. Untuk performa model dalam pengujian kali ini dapat ditunjukkan dalam bentuk *confusion matrix* dan juga *classification report* yang memuat nilai *accuracy*, *precision*, *recall*, dan *f1-score* yang akan ditampilkan pada sub-bab komparasi *classification report*.

Tabel 5. Distribusi Dataset Pengujian dengan *Test Data*

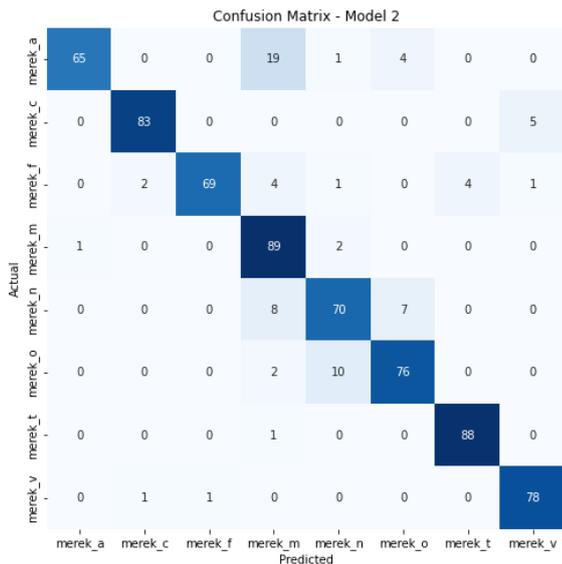
No.	Class	Jumlah Citra
1.	merek_a	89
2.	merek_c	88
3.	merek_f	81
4.	merek_m	92
5.	merek_n	85
6.	merek_o	88
7.	merek_t	89
8.	merek_v	80
Total keseluruhan		692

Pengujian arsitektur *MobileNetV2* dengan tipe *Head Model* 1 berdurasi selama 9.63 menit atau 578 detik. Hasil pengujian menunjukkan bahwa model ini berhasil mengklasifikasikan citra dengan benar sebanyak 80 citra dari merek\_a, 79 citra dari merek\_c, 79 citra dari merek\_f, 87 citra dari merek\_m, 72 citra dari merek\_n, 72 citra dari merek\_o, 88 citra dari merek\_t, dan 76 citra dari merek\_v, sebagaimana bentuk *confusion matrix* yang tertera pada Gambar 10.



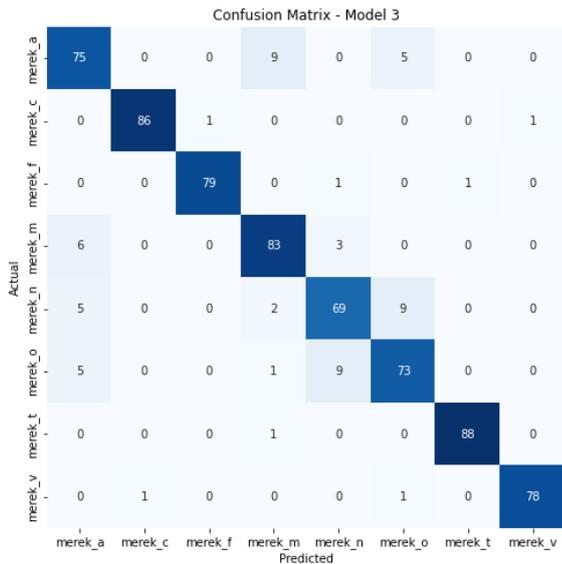
Gambar 10. *Confusion Matrix* Tipe *Head Model* 1

Pengujian arsitektur *MobileNetV2* dengan tipe *Head Model* 2 berdurasi selama 8.93 menit atau 536 detik. Hasil pengujian menunjukkan bahwa model ini berhasil mengklasifikasikan citra dengan benar sebanyak 65 citra dari merek\_a, 83 citra dari merek\_c, 69 citra dari merek\_f, 89 citra dari merek\_m, 70 citra dari merek\_n, 76 citra dari merek\_o, 88 citra dari merek\_t, dan 78 citra dari merek\_v, sebagaimana bentuk *confusion matrix* yang tertera pada Gambar 11.



Gambar 11. Confusion Matrix Tipe Head Model 2

Pengujian arsitektur *MobileNetV2* dengan tipe *Head Model 3* berdurasi selama 9.1 menit atau 546 detik. Hasil pengujian menunjukkan bahwa model ini berhasil mengklasifikasikan citra dengan benar sebanyak 75 citra dari merek\_a, 86 citra dari merek\_c, 79 citra dari merek\_f, 83 citra dari merek\_m, 69 citra dari merek\_n, 73 citra dari merek\_o, 88 citra dari merek\_t, dan 78 citra dari merek\_v, sebagaimana bentuk *confusion matrix* yang tertera pada Gambar 12.



Gambar 12. Confusion Matrix Tipe Head Model 3

C. Pengujian Model CNN Tunggal dengan Random Image

Pengujian ini dilakukan hanya untuk menguji Model CNN Tunggal. Dalam pengujian ini, dataset yang digunakan sebanyak 32 citra per *class*, sehingga total keseluruhan dataset sebanyak 256 citra. Arsitektur *MobileNetV2* dengan tipe *Head Model 1*, *Head Model 2*, dan *Head Model 3* memiliki hasil pengujian yang tertera dalam Tabel 6.

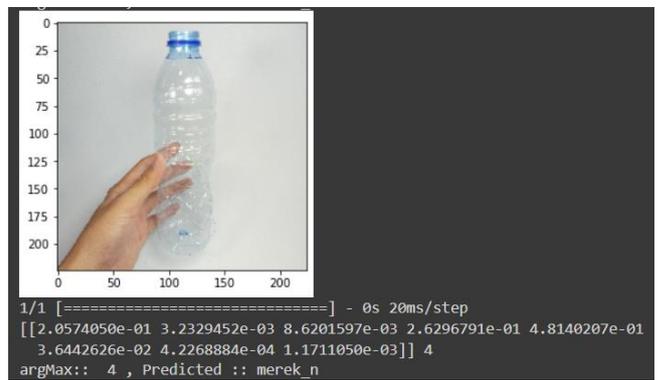
Tabel 6. Hasil Pengujian dari Berbagai Tipe Head Model dengan Random Image

No.	Arsitektur	Prediksi Benar	Prediksi Salah	Persentase (%)
1.	Head Model 1	162	94	63.28
2.	Head Model 2	150	106	58.59
3.	Head Model 3	167	89	65.23

Berdasarkan Tabel 6, maka arsitektur dengan tipe *Head Model 3* memiliki hasil pengujian paling tinggi di antara arsitektur dengan tipe *head model* lainnya, di mana total prediksi benar sebanyak 167 dari 256 citra dan persentase sebesar 65.23%. Sedangkan, arsitektur dengan tipe *Head Model 2* memiliki hasil paling rendah dibandingkan lainnya, yaitu memiliki total prediksi benar sebanyak 150 dari 256 citra dengan persentase sebesar 58.59%. Selisih nilai persentase dari ketiga tipe *head model* tersebut berkisar 1.95% hingga 6.64%. Beberapa contoh hasil klasifikasi atau prediksi citra yang dilakukan pada pengujian *random image* ini terdapat pada Gambar 13.



(a)



(b)

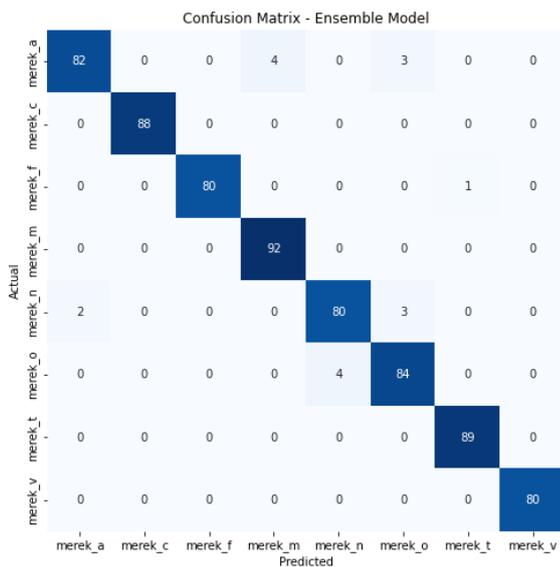
Gambar 13. Hasil Pengujian dengan Random Image (a) Prediksi Benar (b) Prediksi Salah

D. Pengujian Ensemble Model dan Komparasi Classification Report

Setelah dilakukan *ensemble* dari ketiga model CNN tunggal, maka akan dilakukan pengujian pada *ensemble* model atau E-CNN. Pengujian dilakukan menggunakan dataset *test data* yang berjumlah 692 citra dari berbagai *class*, sebagaimana Tabel 5

sebelumnya yang menjelaskan tentang distribusi dataset pengujian dengan *test data*. *Output* dari pengujian ini berbentuk *confusion matrix*, serta terdapat *classification report* berupa *accuracy*, *precision*, *recall*, dan *f1-score*.

Pengujian model E-CNN memiliki durasi selama 10.52 menit atau 631 detik. Hasil pengujian menunjukkan bahwa model E-CNN berhasil mengklasifikasikan citra dengan benar sebanyak 82 citra dari merek\_a, 88 citra dari merek\_c, 80 citra dari merek\_f, 92 citra dari merek\_m, 80 citra dari merek\_n, 84 citra dari merek\_o, 89 citra dari merek\_t, dan 80 citra dari merek\_v, sebagaimana bentuk *confusion matrix* yang tertera pada Gambar 14.



Gambar 14. *Confusion Matrix* Model E-CNN

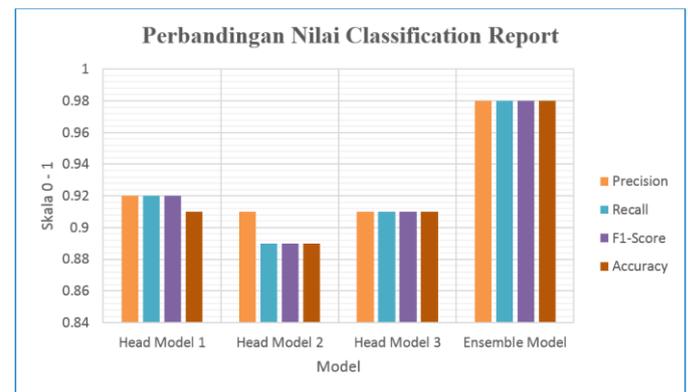
Pada *confusion matrix* model CNN tunggal, arsitektur dengan tipe *Head Model 1* memiliki klasifikasi benar sebanyak 633 dari 692 citra, kemudian pada arsitektur dengan tipe *Head Model 2* memiliki klasifikasi benar sebanyak 618 dari 692 citra, kemudian pada arsitektur dengan tipe *Head Model 3* memiliki klasifikasi benar sebanyak 631 dari 692 citra. Sedangkan, pada *ensemble* model atau E-CNN memiliki klasifikasi benar sebanyak 675 dari 692 citra.

Pada Tabel 7 terdapat *classification report* yang berisi nilai *accuracy*, *precision*, *recall*, dan *f1-score* milik model E-CNN dan juga milik model CNN tunggal, seperti arsitektur *MobileNetV2* dengan tipe *Head Model 1*, *Head Model 2*, dan *Head Model 3*. Dari Tabel 7 dapat diketahui bahwa nilai hasil *classification report* milik setiap model dapat dikatakan cukup baik dalam mengklasifikasikan citra pada potret botol minuman bekas tersebut. Akan tetapi, model E-CNN dapat dikatakan lebih unggul atau optimal dibandingkan seluruh model CNN tunggal. Selisih *accuracy* antara model E-CNN dengan berbagai model CNN tunggal sebesar 7% hingga 9%. Model yang mempunyai nilai terendah, baik dari sisi *accuracy*, maupun *macro average* dari *precision*, *recall*, dan *f1-score* adalah model CNN tunggal berupa arsitektur *MobileNetV2* dengan tipe *Head Model 2*.

Tabel 7. Nilai Hasil *Classification Report*

Arsitektur	Report Type (macro average)			Accuracy
	Precision	Recall	F1-score	
Head Model 1	0.92	0.92	0.92	0.91
Head Model 2	0.91	0.89	0.89	0.89
Head Model 3	0.91	0.91	0.91	0.91
Ensemble Model	0.98	0.98	0.98	0.98

Untuk memudahkan dalam mengamati perbandingan nilai *accuracy*, serta nilai rata-rata (*macro average*) dari *precision*, *recall*, dan *f1-score* pada Tabel 7, maka ditampilkan Gambar 15 berupa grafik batang yang ditunjukkan berikut ini.



Gambar 15. Perbandingan Nilai Hasil *Classification Report*

## V. KESIMPULAN

Berdasarkan hasil perancangan, pelatihan, pengujian, serta dilakukan suatu analisis pada penelitian ini, maka dapat ditarik beberapa kesimpulan sebagai berikut.

- Algoritma *Convolutional Neural Network* (CNN) dalam mengklasifikasikan citra pada potret botol minuman bekas tidak serta-merta dapat bekerja dengan optimal. Di antara faktor penting dalam meningkatkan kinerja klasifikasi gambar ialah melakukan pengolahan dataset atau *image pre-processing*. Salah satu cara pengolahan dataset adalah dengan *data augmentation* agar memperkaya ragam atau fitur dari dataset gambar, seperti proses *rotation*, *rescale*, *flip*, *zoom*, dan sebagainya.
- Nilai rata-rata *accuracy* pelatihan pada arsitektur *MobileNetV2* dengan tipe *Head Model 1*, *Head Model 2*, dan *Head Model 3* secara berturut-turut sebesar 73.61%, 74.53%, dan 71.16%. Selain itu, ketiga tipe *head model* ini memiliki rentang waktu pelatihan yang tidak berbeda jauh secara signifikan, yaitu antara 18 hingga 103 detik.
- Hasil pengujian dengan dataset *test data* yang termuat pada *classification report* menunjukkan bahwa model CNN tunggal, yakni arsitektur *MobileNetV2* dengan tipe *Head Model 1*, *Head Model 2*, dan *Head Model 3* memiliki nilai

*accuracy* berturut-turut sebesar 91%, 89%, dan 91%. Sedangkan, model *Ensemble Convolutional Neural Network* (E-CNN) memperoleh nilai *accuracy* sebesar 98%, di mana selisih nilai *accuracy* antara model E-CNN dengan berbagai model CNN tunggal sebesar 7% hingga 9%. Selain itu, rentang waktu pengujian seluruh model tidak berbeda jauh secara signifikan, yaitu berkisar antara 53 hingga 95 detik.

#### UCAPAN TERIMA KASIH

Terima kasih kepada seluruh pihak yang telah membantu dalam penelitian ini, yaitu kepada dosen teknik elektro, teman-teman elektro, dan seluruh pihak yang tidak dapat disebutkan satu per satu. Kemudian, penulis mengucapkan terima kasih kepada berbagai pihak dari tim editorial Jurnal Teknologi Elektro serta Universitas Mercu Buana atas dipublikasikannya penelitian ini.

#### DAFTAR PUSTAKA

- [1] M. I. Utami and D. E. A. F. Ningrum, "Proses Pengolahan Sampah Plastik di UD Nialdho Plastik Kota Madiun," *Indonesian Journal of Conservation*, vol. 9, no. 2, pp. 89-95, 2020.
- [2] Kementerian Lingkungan Hidup dan Kehutanan, 2021. [Online]. Available: <https://sipsn.menlhk.go.id/sipsn/>. [Accessed 26 September 2022].
- [3] I. Febriadi, "Pemanfaatan Sampah Organik dan Anorganik untuk Mendukung Go Green Concept di Sekolah," *ABDIMAS: Papua Journal of Community Service*, vol. 1, no. 1, pp. 32-39, 2019.
- [4] H. M. Arum, Jamiati, M. Ineza, F. M. R. Kusumo and R. Amelia, "Pemanfaatan Barang Bekas Botol Plastik Dalam Pembuatan Vertical Garden Di Wilayah Lamtoro Pamulang Timur," in *SEMNASKAT LPPM UMJ*, Jakarta, 2019.
- [5] U. N. Oktaviana and Y. Azhar, "Klasifikasi Sampah Menggunakan Ensemble DenseNet169," *JURNAL RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 6, pp. 1207-1215, 2021.
- [6] A. Mikołajczyk and M. Grochowski, "Data augmentation for improving deep learning in image classification problem," in *International Interdisciplinary PhD Workshop (IIPhDW)*, Lublin, 2018.
- [7] N. Jmour, S. Zayen and A. Abdelkrim, "Convolutional Neural Networks for image classification," in *International Conference on Advanced Systems and Electric Technologies (IC\_ASET)*, Hammamet, 2018.
- [8] T. Shanthi and R. S. Sabeenian, "Modified Alexnet architecture for classification of diabetic retinopathy images," *Computers and Electrical Engineering*, vol. 76, pp. 56-64, 2019.
- [9] J. Feriawan and D. Swanjaya, "Perbandingan Arsitektur Visual Geometry Group dan MobileNet Pada Pengenalan Jenis Kayu," *SEMNAS INOTEK (Seminar Nasional Inovasi Teknologi)*, vol. 4, no. 3, pp. 185-190, 2020.
- [10] A. G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, M. Andreetto and H. Adam, "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications," *Computer Science*, pp. 1-9, 2017.
- [11] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov and L.-C. Chen, "MobileNetV2: Inverted Residuals and Linear Bottlenecks," in *Conference on Computer Vision and Pattern Recognition (CVPR)*, Salt Lake City, 2018.
- [12] R. Indraswari, W. Herulambang and R. Rokhana, "Deteksi Penyakit Mata Pada Citra Fundus Menggunakan Convolutional Neural Network (CNN)," *Techno.COM*, vol. 21, no. 2, pp. 378-389, 2022.
- [13] S. Chatterjee, D. Hazra and Y.-C. Byun, "IncepX-Ensemble: Performance Enhancement Based on Data Augmentation and Hybrid Learning for Recycling Transparent PET Bottles," *IEEE Access*, vol. 10, pp. 52280-52293, 2022.
- [14] I. Ren, F. Zahiri, G. Sutton, T. Kurfess and C. Saldana, "A Deep Ensemble Classifier for Surface Defect Detection in Aircraft Visual Inspection," *Smart and Sustainable Manufacturing Systems*, vol. 4, no. 1, pp. 1-31, 2020.
- [15] A. S. Nugroho, R. Umar and A. Fadlil, "Klasifikasi Botol Plastik Menggunakan Multiclass Support Vector Machine," *Jurnal Khatulistiwa Informatika (JKI)*, vol. 9, no. 2, pp. 79-85, 2021.
- [16] I. N. Pratama, T. Rohana and T. A. Mudzakir, "Pengenalan Sampah Plastik Dengan Model Convolutional Neural Network," in *Conference on Innovation and Application of Science and Technology (CIASTECH)*, Malang, 2020.
- [17] A. S. Nugroho, R. Umar and A. Fadlil, "Sistem Pengenalan Botol Plastik Berdasarkan Label Merek Menggunakan Faster-RCNN," *TECHNO*, vol. 21, no. 2, pp. 111-118, 2020.
- [18] R. Valentina, S. Rostianingsih and A. N. Tjondrowiguno, "Pengenalan Gambar Botol Plastik dan Kaleng Minuman Menggunakan Metode Convolutional Neural Network," *JURNAL INFRA*, vol. 8, no. 1, pp. 249-254, 2020.
- [19] D. Gunawan and H. Setiawan, "Convolutional Neural Network dalam Analisis Citra Medis," *KONSTELASI*, vol. 2, no. 2, pp. 376-390, 2022.
- [20] K. H. Mahmud, Adiwijaya and S. A. Faraby, "Klasifikasi Citra Multi-kelas Menggunakan Convolutional Neural Network," in *e-Proceeding of Engineering*, Bandung, 2019.
- [21] J. Xu, Y. Zhang and D. Miao, "Three-way confusion matrix for classification: A measure driven view," *Information Sciences*, vol. 507, pp. 772-794, 2019.
- [22] P. O. Parasian and F. Utaminingrum, "Rancang Bangun Sistem Pengklasifikasi Jenis Sampah Organik dan Sampah Daur Ulang menggunakan Resnet50," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer (JPTIIK)*, vol. 6, no. 4, pp. 1994-1999, 2022.