

# Pengenalan Gambar Botol Plastik dan Kaleng Minuman Menggunakan Metode Convolutional Neural Network

Regina Valentina, Silvia Rostianingsih, Alvin Nathaniel Tjondrowiguno

Program Studi Informatika Fakultas Teknologi Industri Universitas Kristen Petra

Jl. Siwalankerto 121 – 131 Surabaya 60236

Telp. (031) – 2983455, Fax. (031) – 8417658

E-Mail: reginavalentina0198@gmail.com, silvia@petra.ac.id, alvin.nathaniel@petra.ac.id

## ABSTRAK

Sampah botol plastik dan kaleng merupakan sampah anorganik yang tidak dapat diuraikan oleh bakteri secara alami dan membutuhkan waktu lama untuk penguraiannya. Hingga saat ini kesadaran masyarakat untuk peduli terhadap lingkungan masih rendah. Padahal pemilahan sampah sangatlah penting dilakukan sebelum sampah didaur ulang. Menurut Dinas Lingkungan Hidup, Kebersihan dan Pertamanan Kota Kediri, sampah seperti plastik dan kaleng membutuhkan perlakuan khusus dalam proses daur ulangnya. Proses pemilahan sampah hingga saat ini masih dilakukan secara manual oleh manusia. Proses ini membutuhkan tenaga yang cukup besar, waktu yang lama dan belum dapat mengatasi banyaknya sampah yang ada.

Pada penelitian ini akan menggunakan metode *Convolutional Neural Network* (CNN) untuk pengenalan objek. Telah terdapat beberapa penelitian mengenai pengklasifikasian sampah, tetapi dalam kedua penelitian tersebut objek yang digunakan hanyalah sampah berbahan plastik. Belum terdapat pengenalan terhadap sampah berbahan kaleng. Maka dari itu, pada penelitian ini akan dilakukan pengenalan terhadap sampah botol plastik dan kaleng minuman.

Berdasarkan hasil penelitian, activation function yang paling sesuai dengan penelitian adalah ELU. Sedangkan jumlah layer yang digunakan adalah empat layer konvolusi, empat layer max pooling, dan tiga fully connected layer. Sedangkan tingkat learning rate yang digunakan adalah 0.00001, tingkat dropout 0.8, dan jumlah epoch training 50 kali. Dengan menggunakan arsitektur CNN model tersebut, didapatkan tingkat akurasi sebesar 86%.

**Kata Kunci:** *Convolutional Neural Network*, sampah, botol plastik, kaleng, pengenalan gambar

## ABSTRACT

*Plastic bottles and cans are anorganic waste that cannot be decomposed by bacteria naturally and take a long time decomposed. Until now, people awareness to care about the environment is still low. Even though waste sorting is very important before the waste recycling process. According to Kediri City Environment, Hygiene and Gardening Agency, waste such as plastic and cans require special treatment for the recycling process. Until now, the process of sorting waste is still done manually by humans. This process require a lot of energy, a long time and still cannot overcome the amount of the waste nowadays.*

*This research uses Convolutional Neural Network (CNN) method for object recognition. There have been other research about the classification of plastic waste. Both of studies only use plastic waste as the object. There is no studies yet about cans waste. Therefore, this research will carried out an introduction to plastic bottles and cans waste.*

*Based on the result of the study, the activation function that suits the case is ELU. While using four convolutional layers, four max pooling layers, and three fully connected layers in total. This study uses 0.00001 for the learning rate, 0.8 for the dropout rate, and 50 times epoch. The result from test that were done by using this CNN model architecture is an accuracy rate of 86%.*

**Keywords:** *Convolutional Neural Network, waste, plastic bottle, metal can, image recognition*

## 1. PENDAHULUAN

Botol plastik dan kaleng bekas merupakan sampah anorganik dimana sampah ini tidak dapat diuraikan oleh bakteri secara alami dan pada umumnya membutuhkan waktu lama untuk penguraiannya. Meski botol plastik dan kaleng termasuk kategori sampah yang susah diurai, namun masyarakat masih sering menggunakan botol plastik dan kaleng dalam kehidupan sehari-hari. Sehingga sampah berupa botol plastik dan kaleng masih banyak dijumpai hingga hari ini.

Selain itu, hingga saat ini kesadaran masyarakat untuk peduli terhadap lingkungan masih tergolong rendah. Kebanyakan orang masih membuang sampah sembarangan dan tidak mau memilah sampah dengan baik. Padahal pemilahan sampah merupakan salah satu hal penting yang perlu dilakukan sebelum sampah didaur ulang. Sampah dipilah berdasarkan karakteristiknya dan proses daur ulangnya. Menurut Dinas Lingkungan Hidup, Kebersihan dan Pertamanan Kota Kediri, untuk sampah yang susah diuraikan seperti plastik dan kaleng membutuhkan perlakuan khusus dalam proses daur ulangnya. Sampah yang terbuat dari plastik akan didaur ulang dengan cara dilelehkan menjadi bijih plastik dan diolah kembali menjadi produk baru. Meskipun kaleng juga memiliki karakteristik yang susah diuraikan, namun kaleng masih tergolong bahan yang lebih mudah diuraikan dibandingkan plastik. Meskipun memakan waktu yang cukup lama, sampah yang terbuat dari kaleng masih dapat didaur ulang dengan cara ditimbun di tanah. Dapat dikatakan bahwa kaleng memiliki karakteristik yang mirip dengan kayu, dimana apabila kaleng telah berkarat maka akan sangat mudah terurai dalam tanah.

Sebagian besar proses pemilahan sampah yang dilakukan hingga saat ini masih dilakukan secara manual oleh manusia. Hal ini membutuhkan tenaga yang cukup besar dan waktu yang lama. Proses pemilahan sampah yang masih dilakukan secara manual ini belum dapat mengatasi banyaknya sampah yang dihasilkan masyarakat setiap harinya. Sehingga tumpukan sampah akan semakin banyak dan lama kelamaan lahan untuk menampung sampah ini akan habis.

Pada jaman yang telah maju dan berkembang sekarang ini, banyak kegiatan menjadi lebih efisien dengan adanya bantuan teknologi. Pengenalan objek dengan bantuan komputer merupakan salah satu hal yang telah mengatasi masalah-masalah dalam kehidupan. Contoh teknologi pengenalan objek yang telah digunakan sekarang ini adalah pengenalan wajah, pengenalan sidik jari, pengenalan plat nomor, dan juga pengenalan-pengenalan terhadap objek lain. Oleh karena itu, untuk membantu mengatasi masalah dalam pemilahan sampah plastik dan sampah kaleng, akan dilakukan pengenalan pada komputer terhadap sampah berupa botol plastik dan minuman kaleng.

Terdapat beberapa metode untuk pengenalan objek pada komputer berdasarkan gambar. Salah satu metode yang telah sering digunakan dalam penelitian mengenai pengenalan objek adalah *Convolutional Neural Network* (CNN). Selain itu, terdapat pula penelitian oleh Wang mengenai klasifikasi botol plastik berdasarkan warnanya dengan menggunakan metode *Support Vector Machine* (SVM) yang telah berhasil [8]. Selain itu, terdapat penelitian lain yang dilakukan oleh Özkan mengenai klasifikasi botol plastik adalah pengenalan *Polyethylene Terephthalate* (PET), *Polypropylene* (PP) dan *high-density* (HDPE) pada sampah plastik menggunakan *Support Vector Machine* (SVM) [4]. Namun objek yang digunakan dalam kedua penelitian tersebut merupakan sampah-sampah berbahan plastik. Masih belum terdapat pengenalan terhadap sampah berbahan kaleng. Maka dari itu, pada penelitian ini akan dilakukan pengenalan terhadap sampah botol plastik dan kaleng minuman.

Selain itu, pemilahan sampah dengan menggunakan *metal detector* akan memerlukan biaya yang mahal. Untuk meminimalkan biaya, dapat diterapkan pengenalan objek dengan menggunakan citra digital yang hanya memerlukan sebuah kamera biasa. *Convolutional Neural Network* merupakan metode yang efektif untuk pengenalan objek dalam sebuah gambar [3]. Terdapat banyak penelitian mengenai pengenalan objek dengan metode CNN telah berhasil dengan tingkat akurasi yang tinggi, yaitu dengan rata-rata diatas 90%. Oleh karena itu, pada penelitian ini akan diterapkan metode CNN untuk mengenali sampah botol plastik dan kaleng minuman berdasarkan gambar.

Penelitian ini berfokus pada penentuan parameter untuk *Convolutional Neural Network* yang paling optimal untuk pengenalan botol plastik dan kaleng. Penelitian ini dilakukan dengan menggunakan tingkat akurasi sebagai salah satu penentu tingkat keefektifan model *Convolutional Neural Network*.

## 2. DASAR TEORI

### 2.1. *Convolutional Neural Network*

*Convolutional Network* atau yang biasa dikenal dengan *Convolutional Neural Networks* merupakan gabungan dari tiga ide arsitektur untuk memastikan beberapa derajat atau

pergeseran dan invariant distorsi, yaitu reseptif lokal, pembagian bobot (replikasi bobot), dan terkadang subsampling spasial atau temporal. *Convolutional Neural Networks* (CNN) adalah salah satu *neural networks* (jaringan saraf buatan) yang khusus digunakan untuk memproses data dengan topologi menyerupai *grid* [3]. Metode CNN telah terbukti efektif dalam masalah pengenalan gambar dan pengklasifikasian gambar. Selain itu, CNN merupakan salah satu metode yang populer dan sering digunakan untuk penelitian mengenai *machine learning*. Dasar dari CNN adalah sebuah *neural network* yang menggunakan sebuah operasi matematika, yaitu operasi konvolusi untuk menggantikan operasi multiplikasi matriks-matriks yang terdapat pada setiap layer yang ada pada CNN. Operasi konvolusi sendiri adalah sebuah fungsi yang dikhususkan dalam operasi linear pada matematika.

Bentuk model dari CNN merupakan layer-layer jaringan yang saling terkoneksi. Pada umumnya, terdapat tiga layer utama yang digunakan untuk membuat sebuah model CNN, yaitu *convolutional layer*, *pooling layer*, dan *fully connected layer*. Layer konvolusi akan diikuti oleh layer *pooling* yang akan diulang beberapa kali. Hasil dari layer konvolusi dan layer *pooling* akan diolah pada *fully connected layer* sehingga dapat memberikan hasil akhir dari klasifikasi pada *input*.

Untuk melatih model CNN, dataset tidak akan dapat diingat oleh model dalam satu kali proses saja. Proses ketika seluruh dataset sudah melewati *Neural Network* sebanyak satu kali dihitung sebagai satu kali *epoch*. Dalam proses *training* model, dataset yang digunakan akan melewati *Neural Network* (model CNN) beberapa kali supaya dapat menghasilkan model CNN yang baik.

#### 2.1.1. *Convolutional Layer*

Pada *convolutional layer*, dilakukan operasi konvolusi yang kemudian dilanjutkan dengan operasi detector stage menggunakan *activation function*. *Convolution* merupakan sebuah operasi matematika berupa perkalian antara dua matriks yang dilakukan pada setiap *pixel* input dengan kernel atau *filter*. *Filter* merupakan sebuah matriks dengan ukuran tertentu ( $n \times n$ ) yang akan digeser ke seluruh bagian dari input untuk mendapatkan *feature* dari setiap pixel pada input gambar. *Filter* yang digunakan akan bergeser dan dilakukan operasi konvolusi pada setiap bagian dari *input*. Hasil dari setiap operasi itu adalah sebuah *feature* yang akan digunakan pada layer berikutnya. Dalam melakukan operasi konvolusi akan terdapat 4 parameter utama, yaitu:

- *Depth* : jumlah *filter* yang digunakan dalam proses *convolution*.
- *Ksize* : ukuran dari filter yang digunakan dalam proses *convolution*.
- *Stride* : jumlah pergeseran *filter* pada *input* gambar dalam proses *convolution*.
- *Zero-padding* : menunjukkan apakah bahwa bagian tepi dari *input* gambar diberi nilai 0 pada saat proses *convolution* atau tidak.

Pada tahap *activation function*, hasil *feature* dari tahap konvolusi akan diproses dengan sebuah fungsi aktivasi nonlinear. Pada umumnya, fungsi yang sering digunakan dalam model CNN adalah fungsi aktivasi *Rectified Linear* (ReLU) [7]. ReLU merupakan sebuah fungsi  $\max(0,x)$  dimana fungsi ini akan

mengambil nilai maksimal antara 0 dan nilai hasil dari proses konvolusi. Dengan menggunakan fungsi ini, maka semua unit yang memiliki nilai negatif akan dikonversi menjadi nilai 0 dan tidak mengubah unit yang memiliki nilai positif. Dengan menggunakan fungsi ReLU, proses training dapat dilakukan dengan lebih cepat, tetapi dengan menggunakan Leaky ReLU, masalah mengenai nilai gradien yang hilang dapat diatasi [6].

### 2.1.2. Pooling Layer

Hasil dari layer konvolusi akan menjadi *input* pada *pooling layer*. *Pooling layer* digunakan untuk mengurangi dimensi atau ukuran (*width* dan *height*, tanpa mengurangi dimensi *depth*) dari *feature map* yang telah dihasilkan sebelumnya. Hal ini dilakukan dengan tujuan supaya *feature map* yang dihasilkan hanya menyimpan informasi yang dianggap penting dari *feature map* tersebut dengan ukuran dimensi yang kecil[5]. Dengan begitu, waktu yang dibutuhkan untuk melakukan *training data* akan menjadi lebih singkat dan juga mencegah adanya *overfitting*. Terdapat beberapa fungsi yang dapat digunakan dalam proses *pooling layer*, seperti MAX, AVERAGE. Fungsi *pooling* yang paling umum digunakan dalam mengolah data gambar dalam CNN adalah fungsi MAX *pooling*. MAX *pooling* merupakan sebuah fungsi untuk mengambil nilai tertinggi dari setiap matriks *pooling*. Sedangkan AVERAGE *pooling* merupakan sebuah fungsi yang mengambil nilai rata-rata dari area *pooling kernel*. Pada umumnya, hanya terdapat satu metode yang digunakan dalam sebuah model CNN

### 2.1.3. Fully Connected Layer

Setelah layer konvolusi dan *pooling layer*, layer terakhir dalam model CNN adalah *fully connected layer*. *Output* dari *convolutional* dan *pooling layer* merupakan sebuah matriks 3D, sedangkan *input* yang diharapkan pada *fully connected layer* adalah sebuah matriks 1D. Oleh karena itu, hasil dari *convolutional* dan *pooling layer* akan diproses terlebih dahulu dalam operasi *flattening* untuk mengubah ukurannya menjadi sebuah matriks 1D. Pada *fully connected layer*, setiap unit neuron akan saling dihubungkan agar menjadi *multi-layer perceptron*. Setelah itu, akan dilakukan klasifikasi data input (x) terhadap label yang ada (y). Hasil dari klasifikasi data input akan diambil berdasarkan nilai tertinggi yang terdapat pada hasil *fully connected layer*.

### 2.1.4. Dropout Layer

*Dropout* digunakan untuk menghindari adanya *over-fitting*[1]. Proses *over-fitting* dapat dihindari dengan menggunakan layer *dropout* karena adanya peningkatan pada generalisasi data pada model. Salah satu alasan terjadinya *over-fitting* adalah bobot dalam unit neuron pada model CNN yang terlalu banyak dan kompleks sehingga menyebabkan proses *training* yang berlebihan. Semakin tinggi tingkat dropout yang digunakan, maka data dalam model CNN akan lebih digeneralisasikan. Sebaliknya, apabila persentase dropout rendah, atau bahkan tidak menggunakan dropout layer, bobot dalam unit neuron pada model CNN juga akan dihilangkan sedikit dan tingkat kompleksitas model hanya akan berkurang sedikit.


Proses *dropout* pada model CNN cukup sederhana. Bahkan sebuah model yang telah mencapai tingkat akurasi 95% dapat naik sebanyak 2% hanya dengan menggunakan layer *dropout*.

*Dropout* dilakukan pada proses *training* dimana unit neuron pada jaringan saraf buatan tidak akan gunakan berdasarkan probabilitas *dropout-rate*. *Dropout-rate* biasanya merupakan sebuah parameter dengan tipe *float* seperti 0.5. Dengan menggunakan nilai *dropout-rate* 0.5, artinya sebanyak 50% dari total unit neuron tidak akan digunakan pada iterasi tersebut. Dan hanya sisa 50% unit neuron yang akan digunakan dalam proses *training* pada iterasi tersebut. Pemilihan unit neuron yang digunakan dan tidak digunakan pada sebuah iterasi akan dipilih secara acak.

Dengan menggunakan *dropout*, maka akan terdapat unit neuron yang tidak digunakan secara sengaja. Hal ini dilakukan untuk mencegah model terlalu bergantung pada beberapa unit neuron dan memaksa unit neuron untuk dapat bekerja secara independen. *Dropout* dapat diaplikasikan pada input atau unit *hidden layer*, tetapi tidak pada hasil *output*.

## 3. DESAIN SISTEM

### 3.1. Desain Sistem



Gambar 1 Flowchart Sistem

Gambar 1 merupakan *flowchart* dari proses-proses yang dilakukan pada penelitian ini. Dimulai dengan membaca dataset mengenai gambar kaleng dan botol plastik yang telah dikumpulkan dan disortir sebelumnya dengan jumlah total sebanyak 1000 gambar. Dataset gambar dan label akan dikonversi terlebih dahulu menjadi format TFRecords. TFRecords merupakan format penyimpanan biner milik Tensorflow[2]. Dengan menggunakan file biner untuk penyimpanan data, akan memiliki dampak yang signifikan terhadap proses *import pipeline* dan juga pada proses *training model*. Namun dalam penelitian ini, data sebanyak 1000 gambar

ini akan menjadi dua buah TFRecords yang berbeda. Satu merupakan TFRecords untuk dataset *training* dengan data berjumlah 900 gambar (450 gambar botol plastik dan 450 gambar kaleng). Sedangkan TFRecords yang lain merupakan dataset *testing* dengan data berjumlah 100 gambar gambar (50 gambar botol plastik dan 50 gambar kaleng). Dalam mengolah data menjadi sebuah TFRecords akan dibutuhkan sebuah *feature dictionary*. *Feature dictionary* adalah kumpulan “key” dan “value”, serta tipe data dari *feature* yang disimpan dalam TFRecords.

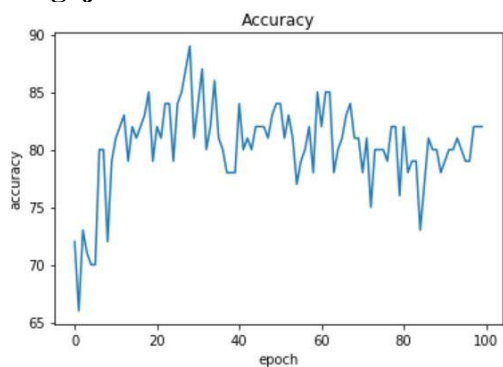
Setelah itu, setiap gambar berupa jpg yang ada dalam *path folder* akan dibaca satu per satu. Setiap gambar akan di-*resize* ulang menjadi ukuran 100x100 pixels tanpa mengubah *channel* pada gambar. Label untuk setiap gambar juga dibuat berdasarkan *path folder* gambar disimpan. Untuk setiap gambar kaleng akan diberi label 1, sedangkan untuk setiap gambar botol plastik akan diberi label 0. Data disimpan dalam bentuk TFRecords berdasarkan *feature dictionary*.

Dengan menggunakan dataset TFRecords sebagai input, dilakukan proses *preprocessing*, yaitu proses untuk membaca TFRecords. TFRecords akan dikonversikan menjadi sebuah dataset yang terdiri dari gambar dan label yang dapat diolah pada model CNN. Setelah itu, dilakukan proses *training model* CNN dan *testing model* CNN dengan menggunakan dataset yang telah dibaca. Dalam proses *training model*, *output* dari sistem adalah model CNN, sedangkan *output* dari testing model adalah tingkat akurasi model terhadap data test.

#### 4. PENGUJIAN SISTEM

Waktu yang dibutuhkan untuk melakukan proses *training* dapat berbeda-beda karena beberapa faktor. Spesifikasi *hardware* dan *software* yang digunakan dalam proses *training* merupakan salah satu faktor yang sangat mempengaruhi. Pada penelitian ini, *hardware* yang digunakan memiliki spesifikasi processor Intel® Core™ i7 2.20 GHz, RAM 8 GB, dan menggunakan *Solid State Drive* (SSD). Sedangkan spesifikasi *software* pada komputer adalah sistem operasi Windows 10 Home 64 bit dan anaconda jupyter-notebook 5.7.8. Waktu yang diperlukan untuk melakukan proses *training* ini adalah 4 jam 38 menit 22 detik. Sedangkan proses *training* yang dilakukan pada *hardware* Intel® Core™ i7 2.60 GHz dan RAM 4 GB dengan spesifikasi *software* yang sama membutuhkan waktu yang lebih lama, yaitu 6 jam 12 menit 37 detik.





##### 4.1 Pengujian Desain Sistem Model CNN



Gambar 2 Hasil Akurasi Desain Sistem

Gambar 2 menunjukkan hasil akurasi yang didapatkan oleh CNN model dengan tingkat akurasi akhir 82%. Terdapat 9 gambar kaleng yang salah diklasifikasikan sebagai botol plastik dan juga 9 gambar botol plastik yang salah diklasifikasikan sebagai kaleng.

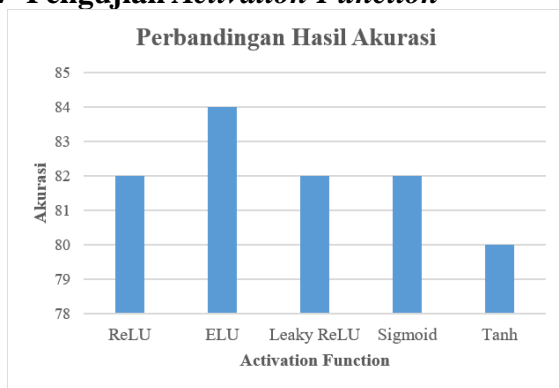
Tabel 1 Contoh Hasil Klasifikasi Desain CNN Model

Gambar	Label Hasil Klasifikasi	Label Sesungguhnya
	Botol Plastik	Kaleng
	Kaleng	Kaleng
	Kaleng	Botol Plastik
	Botol Plastik	Botol Plastik

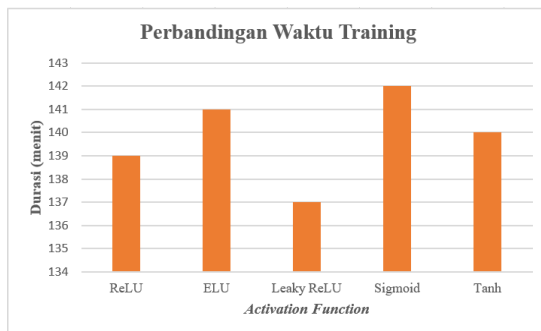
Proses *training* CNN model memakan waktu yang cukup lama, tetapi melalui Gambar 2, dapat dilihat bahwa tingkat akurasi yang didapatkan tidak banyak berubah. Peningkatan tingkat akurasi yang signifikan didapatkan ketika model mengalami proses *training* hingga jumlah epoch mencapai 30. Selain itu,

dapat dilihat bahwa tingkat akurasi model setelah epoch ke-30 menurun dan selalu bergerak stabil pada kisaran 78% - 85%. Sehingga dapat dianggap bahwa CNN model tidak mengalami proses *learning* lagi karena tingkat akurasi yang didapatkan tidak banyak berubah dibandingkan tingkat akurasi sebelumnya dan berada pada tingkat yang sama secara terus menerus. Selain itu, pada penelitian ini CNN model juga tidak menjadi sebuah model yang lebih baik dengan jumlah epoch yang banyak. Oleh karena itu, dapat disimpulkan bahwa dengan menggunakan jumlah epoch 100 tidak membantu penelitian ini untuk menemukan sebuah CNN model yang baik. Sebaliknya, jumlah epoch yang digunakan dapat dikurangi sehingga waktu yang dibutuhkan untuk proses *training* pada mode dapat menjadi lebih singkat. Proses *training* pada CNN model dapat dilakukan dengan lebih efektif karena dengan menggunakan jumlah epoch yang tepat, model CNN dapat mencapai hasil akurasi maksimal dalam jangka waktu yang cukup singkat.

## 4.2 Pengujian Activation Function



Gambar 3 Perbandingan Akurasi Activation Function



Gambar 4 Perbandingan Durasi Training Activation Function

Gambar 3 dan Gambar 4 merupakan hasil akurasi dan durasi yang dibutuhkan untuk pengujian *activation function*. Jumlah *epoch* yang digunakan dalam pengujian ini adalah 50 *epoch*. Berdasarkan hasil pengujian, waktu *training* yang dibutuhkan dengan menggunakan *activation function* Leaky ReLU adalah 2 jam 17 menit dan tingkat akurasi yang didapatkan adalah 82%. Proses *training* model yang menggunakan *activation function* ELU memiliki selisih waktu *training* 4 menit lebih lama, model CNN dapat menghasilkan tingkat akurasi tertinggi yaitu 84% dibandingkan kelima model CNN lain (model yang menggunakan *activation function* ReLU, Leaky ReLU, Sigmoid, dan Tanh). Karena pada penelitian ini tingkat akurasi merupakan

penentu utama untuk pemilihan parameter dan perbedaan durasi antara *activation function* tidak terlalu jauh, maka *activation function* ELU dinilai lebih cocok digunakan untuk penelitian mengenai klasifikasi sampah kaleng dan botol plastik.

## 4.3 Pengujian Jumlah Layer

Tabel 2 Pengujian Jumlah Layer Konvolusi

CNN Model	A1	A2	A3	A4
Layer Konvolusi 1	conv3 - 32	conv3 - 32	<b>conv3 - 32</b>	conv3 - 32
Layer Pooling 1	Max Pooling			
Layer Konvolusi 2	conv3 - 64	conv3 - 64	<b>conv3 - 64</b>	conv3 - 64
Layer Pooling 2	Max Pooling			
Layer Konvolusi 3		conv3 - 128	<b>conv3 - 128</b>	conv3 - 128
Layer Pooling 3		Max Pooling		
Layer Konvolusi 4			<b>conv3 - 256</b>	conv3 - 256
Layer Pooling 4			Max Pooling	
Layer Konvolusi 5				conv3 - 512
Layer Pooling 5				Max Pooling
Model Accuracy	84%	80%	<b>85%</b>	78%
Training Duration	2h 38m 30s	1h 27m 11s	<b>1h 16m 47s</b>	50m 43s

Pada Tabel 2 dapat dilihat bahwa model A4 memiliki tingkat akurasi yang paling rendah dibandingkan model lainnya, bahkan dibawah 80%. Sedangkan model A3 menghasilkan tingkat akurasi tertinggi yaitu 85%.

## 4.4 Analisis Hasil Pengujian

Berdasarkan hasil pengujian yang dilakukan, perubahan pada *activation function* dan jumlah layer. Pada pengujian *activation function*, didapatkan bahwa fungsi yang paling sesuai untuk model CNN pada penelitian ini adalah ELU karena dapat menghasilkan tingkat akurasi yang lebih tinggi dan dalam waktu yang cukup singkat dibandingkan fungsi lain.

Berdasarkan pengujian jumlah layer, didapatkan bahwa semakin banyak jumlah layer yang digunakan, maka waktu yang dibutuhkan untuk proses *training* juga akan berkurang. Hal ini dikarenakan pada setiap layer konvolusi pada CNN model akan selalu diikuti dengan layer *pooling* dengan konfigurasi *ksize* 2x2 dan *stride* 2 yang akan membuat hasil tensor semakin mengecil. Semakin banyak *pooling* layer pada CNN model, maka tensor akhir yang dihasilkan setelah layer *flatten* juga akan semakin kecil. Sebaliknya, model yang memiliki layer konvolusi dan *pooling* yang lebih sedikit akan menghasilkan tensor yang lebih besar. Sebagai contoh, model CNN yang menggunakan dua layer konvolusi dan *pooling* (16 *filter* dan 32 *filter*) akan menghasilkan 20000 *unit neuron* pada layer *flattening*. Sedangkan model CNN yang menggunakan tiga layer konvolusi dan *pooling* (16 *filter*, 32 *filter*, dan 64 *filter*) akan menghasilkan 9216 *unit neuron*, dan

dengan menambahkan layer konvolusi dan pooling yang keempat (128 filter ) didapatkan 4608 *unit neuron* pada layer *flattening*. Hal ini akan memberikan pengaruh pada *fully connected layer*. Semakin besar tensor hasil *flattening* akan membuat *input* pada layer *fully connected layer* semakin besar pula. Hal ini menyebabkan proses pada *fully connected layer* semakin lama karena jumlah *unit neuron* yang akan dihubungkan dalam *fully connected layer* semakin banyak. Sehingga durasi *training* model CNN yang dilakukan juga akan semakin lama dibandingkan model CNN yang menggunakan lebih banyak layer konvolusi dan layer *pooling*.

Berdasarkan hasil pengujian, didapatkan hipotesa bahwa kesalahan dalam proses klasifikasi dapat terjadi apabila proporsi objek terhadap kanvas terlalu kecil, objek diambil dari sisi bawah, dan gambar objek diambil dalam keadaan terpotong dan hanya menampilkan bagian bawah objek. Hal ini dapat disebabkan karena kurangnya *feature* yang dapat diambil apabila gambar terlalu kecil. Selain itu, juga tidak terdapat *feature* yang membedakan bagian bawah botol plastik dengan kaleng minuman.

## KESIMPULAN

Dari hasil perancangan dan pembuatan aplikasi untuk mengklasifikasikan gambar botol plastik dan kaleng, didapatkan kesimpulan antara lain :

- Berdasarkan hasil pengujian, perubahan pada *activation function*, jumlah layer, jumlah *filter*, ukuran *ksize filter*, *learning rate*, metode pada *pooling layer*, dan tingkat *dropout layer* tidak terlalu berpengaruh pada tingkat akurasi yang dihasilkan oleh model.
- Activation function yang paling sesuai untuk penelitian ini adalah ELU.
- Berdasarkan hasil pengujian, model CNN terbaik adalah model yang menggunakan empat layer konvolusi dengan jumlah filter 16-32-64-128.
- Tingkat akurasi yang didapatkan untuk mengklasifikasikan botol plastik dan kaleng dengan menggunakan CNN adalah 86% dengan waktu training 25 menit 12 detik.

## 5. DAFTAR PUSTAKA

- [1] Dertat, A. 2017. *Applied Deep Learning - Part 4: Convolutional Neural Networks*. Retrieved September 4, 2019, from <https://towardsdatascience.com/applied-deep-learning-part-4-convolutional-neural-networks-584bc134c1e2>
- [2] Gamauf, T. 2018. *Tensorflow Records? What they are and how to use them*. Retrieved September 14, 2019, from 20 March 2018 website: <https://medium.com/mostly-ai/tensorflow-records-what-they-are-and-how-to-use-them-c46bc4bbb564>
- [3] Goodfellow, I., Yoshua, B., & Courville, A. 2016. *Deep Learning*. Retrieved May 27, 2019, from MIT Press website: <https://www.deeplearningbook.org/>
- [4] Özkan, K., Ergin, S., Işık, S., & Işikli, I. 2015. *A new classification scheme of plastic wastes based upon recycling labels*. *Waste Management*, 35, 29–35. <https://doi.org/10.1016/j.wasman.2014.09.030>
- [5] Saha, S. 2018. *A Comprehensive Guide to Convolutional Neural Networks — the ELI5 way*. Retrieved May 27, 2019, from <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>
- [6] Stanfords. 2018. *Introduction to Convolutional Neural Networks*. Retrieved May 27, 2019, from [https://web.stanford.edu/class/cs231a/lectures/intro\\_cnn.pdf](https://web.stanford.edu/class/cs231a/lectures/intro_cnn.pdf)
- [7] Udofia, U. 2018. *Basic Overview of Convolutional Neural Network (CNN)*. Retrieved May 27, 2019, from <https://medium.com/@udemeudofia01/basic-overview-of-convolutional-neural-network-cnn-4fcc7dbb4f17>
- [8] Wang, Z., Peng, B., Huang, Y., & Sun, G. 2019. *Classification for plastic bottles recycling based on image recognition*. *Waste Management*, 88, 170–181. <https://doi.org/10.1016/j.wasman.2019.03.032>