

Identifikasi Jenis Sampah Secara Otomatis Menggunakan Metode Convolutional Neural Network (CNN)

Andri Tri Setiawan

Fakultas Teknologi Informasi Universitas Budi Luhur

E-mail: andritrisetiawan86@gmail.com

Abstrak

Sampah merupakan suatu zat sisa yang sudah tidak terpakai dan dibuang yang dihasilkan dari suatu proses produksi domestik (rumah tangga) atau industri. Jumlah timbunan sampa di Indonesia dalam setahun sekitar 67,8 juta ton, jumlah itu akan terus bertambah seiring dengan pertumbuhan jumlah penduduk di Indonesia. Pada umumnya masih banyak masyarakat ketika membuang sampah tidak dipisah antara jenis sampah organik dan jenis sampah anorganik, pencampuran jenis sampah ini membuat kedua jenis sampah tersebut lama terurai. Apabila jenis sampah tersebut dipisah sampah organik memiliki waktu penguraian yang lebih cepat dibandingkan dengan jenis sampah anorganik. Dengan adanya permasalahan ini dapat menggunakan identifikasi jenis sampah secara otomatis menggunakan metode Convolutional Neural Network (CNN) dengan arsitektur model SSD MobileNet. Hasil identifikasi jenis sampah menggunakan Convolutional Neural Network (CNN) dengan 275.000 step menghasilkan akurasi sebesar 93%..

Kata Kunci—Sampah, Convolutional Neural Network (CNN), SSD MobileNet

1. PENDAHULUAN

Sampah merupakan suatu zat sisa yang sudah tidak terpakai dan dibuang yang dihasilkan dari suatu proses produksi domestik (rumah tangga) atau industri. Jumlah timbunan sampah di Indonesia dalam setahun sekitar 67,8 juta ton, jumlah itu akan terus bertambah seiring dengan pertumbuhan jumlah penduduk di Indonesia. Hal ini membuat Tempat Penampungan Akhir (TPA) penuh karena tumpukan sampah yang berlebih yang dapat membuat kerusakan lingkungan sekitar (News Detik, 2020). Jenis sampah yang paling banyak dihasilkan di Indonesia adalah sampah organik sebanyak 60%, sampah plastik 14%, sampah kertas 9%, kaca, kayu dan bahan lainnya 12,7% (CNN Indonesia, 2018).

Menurut Pratama et al. [15] edukasi tentang sampah yang rendah serta kultur lingkungan dan keluarga menjadi faktor yang mempengaruhi tingkat kepedulian masyarakat terhadap sampah, tercatat sebanyak 72% masyarakat Indonesia tidak peduli dengan persoalan sampah. Padahal, masalah sampah dapat diselesaikan di level hulu jika masyarakat melakukan gerakan 3R yaitu reduce, reuse dan recycle.

Sampah organik dan anorganik memiliki lama penguraian yang berbeda. Sampah organik memiliki waktu yang lebih cepat dibandingkan dengan sampah anorganik. Oleh sebab itu sampah organik dan anorganik memiliki cara penanganan daur ulang yang berbeda pula. Pemilahan sampah sebelum ditampung ke Tempat Penampungan Akhir (TPA) sangat penting untuk mengurangi jumlah penimbunan sampah yang terus meningkat setiap tahunnya [6].

Penelitian sebelumnya yang dilakukan oleh Leonardo et al., [8] untuk melakukan klasifikasi sampah daur ulang menggunakan Support Vector Machine dengan fitur Local Binary Pattern. Penelitian ini menggunakan dataset berisi citra sampah yang dapat didaur ulang dibagi menjadi enam kelas masing-masing sekitar 400-500 citra dengan ukuran 400x384 pixel menghasilkan tingkat akurasi kernel linear terbaik yaitu 87,63%. Selanjutnya penelitian

implementasi sistem klasifikasi sampah organik dan anorganik dengan metode jaringan syaraf tiruan backpropagation. Sistem ini dibangun menggunakan sensor LDR, proximity induktif, serta proximity kapasitif dengan hasil sistem mampu melakukan prediksi dengan tingkat keakuratan mencapai 90% [6].

Pengenalan jenis-jenis sampah dapat menggunakan machine learning dengan metode deep learning. Salah satu metode deep learning yang banyak digunakan adalah Convolutional Neural Network (CNN). CNN merupakan pengembangan dari Multi Layer Perceptron (MLP) dan merupakan salah satu algoritma dari Deep Learning. Metode CNN memiliki hasil paling signifikan dalam pengenalan citra, hal tersebut dikarenakan CNN berusaha meniru sistem pengenalan citra pada visual cortex manusia, sehingga memiliki kemampuan mengolah informasi citra [14]. Dan untuk memberikan edukasi tentang sampah kepada masyarakat, dibutuhkan peranan teknologi salah satunya adalah computer vision karena dapat menirukan cara kerja indera penglihatan manusia walaupun tidak bisa menirukan persisi seperti mata manusia karena sistem kerja mata dan otak manusia belum sepenuhnya dipahami [15].

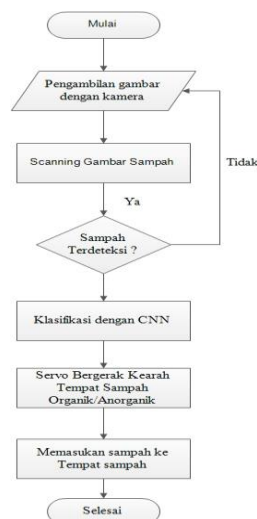
2. METODE PENELITIAN

Metode penelitian pada dasarnya merupakan cara ilmiah untuk mendapatkan data dengan tujuan kegunaan tertentu. Penelitian ini difokuskan untuk mengklasifikasikan sampah organik dan sampah anorganik sehingga dapat dilakukannya identifikasi jenis sampah secara otomatis dengan input berupa gambar dan objek real dengan menggunakan metode Convolutional Neural Network (CNN).

2.1. Sampling/Metode Pemilihan Sampel

Populasi pada penelitian ini adalah citra sampah yang diambil dari Kaggle, Google Image dan citra sampah yang peneliti kumpulkan sendiri. Sedangkan sampel yang digunakan dalam penelitian ini adalah gambar sampah organik dan anorganik. Jumlah keseluruhan gambar yang dikumpulkan untuk sampel sebanyak 4.200 gambar, dengan jumlah gambar sampah organik sebanyak 2.100 gambar dan jumlah gambar sampah anorganik sebanyak 2.100 gambar.


2.2. Rancangan Alur Sistem



Gambar 1. Rancangan Alur Sistem

Penejelasan pada Gambar 1 user mengarahkan sampah kedepan kamera, kemudian sistem akan melakukan scanning terhadap objek sampah yang dibawa oleh user, ketika sampah sudah berhasil terdeteksi maka tutup tempat sampah akan bergerak sesuai dengan objek yang dideteksinya kemudian user memasukkan sampah yang dibawanya ketempat sampah sesuai dengan arah tutup samapha bergerak

2.3. Rancangan Desain Sistem



Gambar 2. Rancangan Desain Sistem

Penjelasan Gambar 2 dari rancangan desain sistem :

1. Webcam berfungsi untuk mengambil gambar jenis sampah yang akan diidentifikasi.
2. Jetson Nano berfungsi untuk pengolahan data dan sebagai tempat penyimpanan program untuk mengendalikan komponen-komponen yang terhubung.
3. Motor servo berfungsi sebagai penggerak/pembuka tempat sampah sesuai dengan jenis sampah yang telah diidentifikasi.
4. Laptop/Monitor yang terhubung ke jetson nano melalui jaringan wireless. Perangkat ini akan berfungsi untuk menampilkan interface dan memberikan perintah terhadap setiap operasi yang dilakukan

2.4. Teknik Pengujian

Confusion Matrix adalah salah satu metode yang dapat digunakan untuk mengukur kinerja suatu metode klasifikasi dan pada dasarnya Confusion Matrix mengandung informasi yang dapat membandingkan hasil klasifikasi yang dilakukan oleh sistem dengan hasil klasifikasi yang seharusnya. Pada dasarnya confusion matrix memuat informasi/penjelasan yang membandingkan hasil pengelompokan yang dilakukan oleh sistem dengan hasil pengelompokan yang seharusnya/semestinya.

Pada pengukuran kinerja dengan menggunakan confusion matrix, terdapat 4 (empat) istilah sebagai representasi hasil proses klasifikasi/pengelompokan. Keempat istilah tersebut adalah True Negative (TN), True Positive (TP), False Positive (FP) dan False Negative (FN). Nilai True Negative (TN) merupakan jumlah data negatif yang terdeteksi dengan benar, Sementara itu, True Positive (TP) merupakan data positif yang terdeteksi benar, sedangkan False Positive (FP) merupakan data negatif namun terdeteksi sebagai data positif. False Negative (FN) adalah antonim dari True Positive, sehingga data positif, namun terdeteksi sebagai data negatif. Pada

jenis klasifikasi binary yang hanya memiliki 2 keluaran kelas. Tabel 3.4 menunjukkan confusion matrix.

Tabel 1. Confusion Matrix

| Kelas | Terklasifikasi Positif | Terklasifikasi Negatif |
|---------|------------------------|------------------------|
| Positif | TP (True Positive) | FN (False Negative) |
| Negatif | FP (False Positive) | TN (True Negative) |

Berdasarkan nilai False Positive (FP), False Negative (FN), True Negative (TN), dan True Positive (TP) dapat diperoleh nilai akurasi, presisi dan recall. Nilai dari akurasi menggambarkan seberapa akurat/cermat suatu sistem dapat mengklasifikasikan data secara benar. Dengan kata lain, nilai akurasi merupakan perbandingan antara data yang ter klasifikasi benar dengan keseluruhan data.

Pada tahap ini akan dijelaskan bagaimana nilai Confusion Matrix didapat berdasarkan penggunaan rumus-rumus yang ada dibawah ini, sebagai berikut:

1. Pada tahap ini dapat dijelaskan bahwa hasil dengan nilai 99-100 persen dapat menjadi sangat baik, bagus, biasa-biasa saja, buruk atau mengerikan itu semua tergantung pada masalahnya.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

2. Pada tahap ini dapat dijelaskan bahwa recall dapat didefinisikan sebagai rasio dari jumlah total contoh positif yang di klasifikasikan dengan benar dan nilai recall yang baik menunjukkan klasifikasi dikenali dengan benar.

$$Recall = \frac{TP}{TP + FN}$$

3. Pada tahap ini dapat dijelaskan bahwa nilai presisi didapatkan dari pembagian jumlah total contoh positif yang diklasifikasikan dengan benar dengan jumlah total contoh positif yang diprediksi.


$$Precesion = \frac{TP}{TP + FN}$$

3. HASIL DAN PEMBAHASAN


Pembahasan terhadap hasil penelitian dan pengujian yang diperoleh disajikan dalam bentuk uraian teoritik, baik secara kualitatif maupun kuantitatif. Hasil percobaan sebaiknya ditampilkan dalam berupa grafik ataupun tabel. Untuk grafik dapat mengikuti format untuk diagram dan gambar

3.1. Pengumpulan Data

Pengumpulan citra sampah organik dan anorganik yang diambil memiliki ukuran yang beragam. Pada tahap ini seluruh data citra akan diatur ulang ukurannya menjadi 300 x 300 pixel. Proses tersebut merupakan proses resizing citra. Tahap resizing citra bertujuan agar proses training terhadap citra sampah organik dan anorganik dapat dengan cepat dilakukan oleh Convulutional Neural Network (CNN).



Gambar 3. Kumpulan Citra Sampah Anorganik



Gambar 4. Kumpulan Citra Sampah Organik

Proses pendeteksian dan pengklasifikasian data objek berbasis citra digital memerlukan jumlah data yang besar untuk dilatih, sehingga mendapatkan hasil yang optimal dalam pendeteksian dan pengklasifikasian objek. Data yang digunakan dalam penelitian ini sebanyak 4.200 gambar. Dataset yang digunakan dalam penelitian ini terdiri dari 2 kategori yaitu sampah organik dan sampah anorganik. Pada tabel 2 menunjukkan kategori sampah.

Tabel 2. Kategori Sampah

| Kategori Sampah | Jumlah Citra |
|------------------|--------------|
| Sampah Organik | 2.100 Citra |
| Sampah Anorganik | 2.100 Citra |

Citra sampah yang sudah dikumpulkan tersebut kemudian dibagi dua bagian yaitu untuk data training dan data testing untuk data training yang digubakan sebnyak 80% dan untuk data testing yang digunakan sebanyak 20%. Pada tabel 2 menunjukkan detail pembagian data training dan data testing.

Tabel 3. Pembagian Data Training dan Data Testing


| Kategori Sampah | Jumlah Citra | Citra Latih | Citra Uji |
|-----------------|--------------|-------------|-----------|
| Sampah Organik | 2.100 Citra | 1.680 | 420 |

| | | | |
|------------------|-------------|-------|-----|
| Sampah Anorganik | 2.100 Citra | 1.680 | 420 |
|------------------|-------------|-------|-----|

3.2. Preprocessing Image

Setelah menyelesaikan tahap pengumpulan data sampah organik dan sampah anorganik, maka selanjutnya akan dilakukan tahapan preprocessing image. Tahapan-tahapan yang akan dilakukan adalah sebagai berikut :

3.2.1. Pelabelan Gambar



Gambar 5. Proses Pelabelan Gambar

Pada tahap ini dilakukan pelabelan setiap objek yang akan dilatih ke dalam sistem dengan memberikan bounding box dan juga pelabelan nama kelas pada masing-masing gambar. Proses pelabelan dilakukan secara manual untuk 4.200 dataset sampah organik dan anorganik menggunakan LabelImg. Proses pelabelan ini menghasilkan sebuah file xml untuk setiap objek pada gambar yang dilabeli.

3.2.2. Konversi Dataset

Setelah masing-masing objek dilabeli dan menghasilkan file dengan ekstensi XML. Konversi data dilakukan untuk mengubah ekstensi pada data yang ada setelah dilakukannya pelabelan pada setiap gambarnya. Agar data pada setiap gambar yang telah diberikan label dapat dimasukkan ke dalam tensorflow maka perlu dilakukan konversi file dari XML ke CSV dan dari CSV ke TFRecord

3.2.3. XML ke CSV

Setelah tahap pelabelan selesai dilakukan, tahap selanjutnya dilakukan konversi data dari XML ke CSV menjadi dua file CSV dengan nama train_label.csv dan test_label.csv. berikut konversi data untuk data training dan data testing dari XML ke CSV.

| | filename | width | height | class | xmin | ymin | xmax | ymax |
|----|-------------------|-------|--------|-----------|------|------|------|------|
| 1 | | | | | | | | |
| 2 | anorganik0.jpg | 300 | 300 | anorganik | 36 | 84 | 251 | 259 |
| 3 | anorganik1.jpg | 300 | 300 | anorganik | 32 | 53 | 246 | 198 |
| 4 | anorganik10.jpg | 300 | 300 | anorganik | 93 | 72 | 210 | 217 |
| 5 | anorganik100.jpg | 300 | 300 | anorganik | 4 | 10 | 299 | 287 |
| 6 | anorganik1001.jpg | 300 | 300 | anorganik | 16 | 86 | 297 | 237 |
| 7 | anorganik1003.jpg | 300 | 300 | anorganik | 3 | 60 | 300 | 251 |
| 8 | anorganik1003.jpg | 300 | 300 | anorganik | 77 | 148 | 260 | 286 |
| 9 | anorganik101.jpg | 300 | 300 | anorganik | 71 | 75 | 236 | 275 |
| 10 | anorganik1011.jpg | 300 | 300 | anorganik | 39 | 47 | 123 | 295 |
| 11 | anorganik1011.jpg | 300 | 300 | anorganik | 77 | 25 | 142 | 282 |
| 12 | anorganik1011.jpg | 300 | 300 | anorganik | 116 | 19 | 166 | 284 |
| 13 | anorganik1011.jpg | 300 | 300 | anorganik | 156 | 18 | 204 | 283 |
| 14 | anorganik1011.jpg | 300 | 300 | anorganik | 203 | 24 | 239 | 283 |
| 15 | anorganik1011.jpg | 300 | 300 | anorganik | 224 | 28 | 288 | 136 |
| 16 | anorganik1013.jpg | 300 | 300 | anorganik | 17 | 65 | 250 | 300 |
| 17 | anorganik1015.jpg | 300 | 300 | anorganik | 59 | 44 | 276 | 99 |
| 18 | anorganik1015.jpg | 300 | 300 | anorganik | 51 | 90 | 281 | 151 |
| 19 | anorganik1015.jpg | 300 | 300 | anorganik | 4 | 147 | 287 | 203 |
| 20 | anorganik1015.jpg | 300 | 300 | anorganik | 5 | 199 | 292 | 271 |
| 21 | anorganik1016.jpg | 300 | 300 | anorganik | 78 | 91 | 193 | 194 |
| 22 | anorganik1017.jpg | 300 | 300 | anorganik | 28 | 54 | 278 | 244 |
| 23 | anorganik102.ioe | 300 | 300 | anorganik | 42 | 75 | 243 | 282 |

Gambar 5. Hasil Konversi XML ke CSV

3.2.4. Konversi Dataset CSV ke TFRecord

Data yang sudah dikonversi menjadi CSV kemudian data tersebut dikonversi kembali menjadi Tfrecored. Data yang sudah diberikan label diubah ekstensinya agar gambar dapat dimasukkan kedalam sistem untuk proses training data. Konversi dalam bentuk TFRecord akan digunakan untuk feeding (Pertukaran) data pada saat proses training berlangsung. Konversi TFRecord ini dilakukan pada data training dan data testing.

3.2.5. Mengatur Label Map

Setelah proses konversi data selesai dilakukan, selanjutnya membuat file label map. Label map ini digunakan untuk memetakan label yang akan digunakan untuk memberikan penamaan pada objek yang akan dideteksi.

```

item {
  id: 1
  name: 'organik'
}
item {
  id: 2
  name: 'anorganik'
}

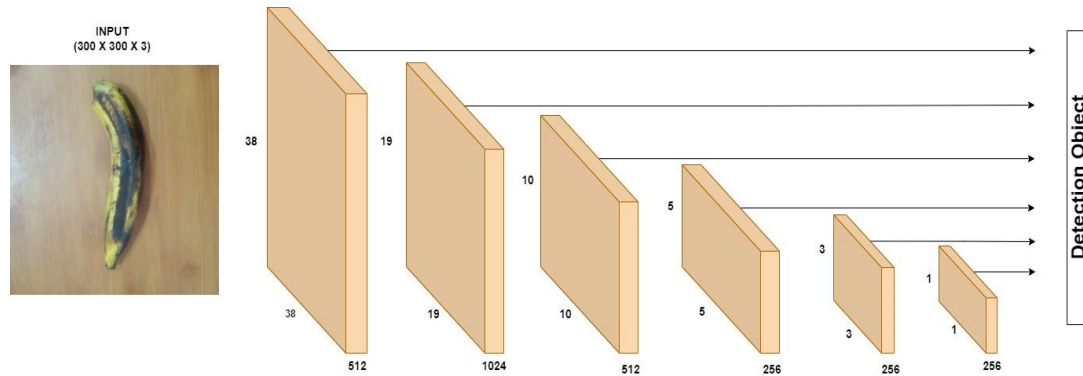
```

Gambar 6. Gambar Isi Label Map

Gambar 6 menunjukkan bahwa ada 2 kelas yang akan digunakan yaitu organik dan anorganik

3.3. Pemodelan Jaringan Convolutional Neural Network (CNN)

Setelah melalui beberapa tahapan yaitu pelabelan gambar, konversi data, selanjutnya data yang dikumpulkan akan ditraining menggunakan algoritma Convolutional Neural Network dengan arsitektur SSD Mobilenet. Desain arsitektur CNN terdiri dari beberapa baguan jaringan yaitu, image for detection, input neuron, convolutional + activation (ReLU) + pooling layer, fully connected layer, classification dan detection output. Berikut ini adalah visualisasi arsitektur jaringan Convolutional Neural Network (CNN).



Gambar 7. Pemodelan Jaringan CNN

Pada Gambar 7 dapat diketahui beberapa bagian diantaranya adalah Image for detection merupakan gambar yang akan dilatih untuk dideteksi. Inputan gambar yang digunakan pada pelatihan data pada penelitian ini sebesar 300x300x3. Angka 3 yang dimaksud adalah sebuah citra yang memiliki 3 channel yaitu RGB (Red, Green, Blue). Sehingga yang masuk kedalam layer pertama atau bagian input neuron sebanyak 270.000 neuron yang didapat dari perhitungan 300x300x3.

3.4. Proses Training

Tahapan utama dari neural network adalah training model, di mana semua dataset akan untuk mengenali dan mempelajari jenis sampah organik dan sampah anorganik. Semua proses yang ada pada jaringan Convolutional Neural Network (CNN) akan bekerja pada proses training model.

```


C:\Windows\System32\cmd.exe
1215 85:49:42.407898 12444 learning.py:512] global step 274979: loss = 2.4869 (1.328 sec/step)
INFO:tensorflow:global step 274980: loss = 2.7488 (1.297 sec/step)
1215 85:49:43.704692 12444 learning.py:512] global step 274980: loss = 2.7488 (1.297 sec/step)
INFO:tensorflow:global step 274981: loss = 2.2439 (1.312 sec/step)
1215 85:49:45.017104 12444 learning.py:512] global step 274981: loss = 3.2439 (1.312 sec/step)
INFO:tensorflow:global step 274982: loss = 3.0025 (1.297 sec/step)
1215 85:49:46.291382 12444 learning.py:512] global step 274982: loss = 3.0025 (1.297 sec/step)
INFO:tensorflow:global step 274983: loss = 2.4530 (1.281 sec/step)
1215 85:49:47.595038 12444 learning.py:512] global step 274983: loss = 2.4530 (1.281 sec/step)
INFO:tensorflow:global step 274984: loss = 2.3962 (1.312 sec/step)
1215 85:49:48.923975 12444 learning.py:512] global step 274984: loss = 2.3962 (1.312 sec/step)
INFO:tensorflow:global step 274985: loss = 2.4630 (1.312 sec/step)
1215 85:49:50.235489 12444 learning.py:512] global step 274985: loss = 2.4630 (1.312 sec/step)
INFO:tensorflow:global step 274986: loss = 2.2847 (1.281 sec/step)
1215 85:49:51.516648 12444 learning.py:512] global step 274986: loss = 2.2847 (1.281 sec/step)
INFO:tensorflow:global step 274987: loss = 2.3661 (1.297 sec/step)
1215 85:49:52.813458 12444 learning.py:512] global step 274987: loss = 2.3661 (1.297 sec/step)
INFO:tensorflow:global step 274988: loss = 2.4433 (1.344 sec/step)
1215 85:49:54.157109 12444 learning.py:512] global step 274988: loss = 2.4433 (1.344 sec/step)
INFO:tensorflow:global step 274989: loss = 2.3124 (1.328 sec/step)
1215 85:49:55.485137 12444 learning.py:512] global step 274989: loss = 2.3124 (1.328 sec/step)
INFO:tensorflow:global step 274990: loss = 1.8167 (1.297 sec/step)
1215 85:49:56.781932 12444 learning.py:512] global step 274990: loss = 1.8167 (1.297 sec/step)
INFO:tensorflow:global step 274991: loss = 1.9449 (1.297 sec/step)
1215 85:49:58.094339 12444 learning.py:512] global step 274991: loss = 1.9449 (1.297 sec/step)
INFO:tensorflow:global step 274992: loss = 1.9401 (1.312 sec/step)
1215 85:49:59.406747 12444 learning.py:512] global step 274992: loss = 1.9401 (1.312 sec/step)
INFO:tensorflow:global step 274993: loss = 2.4774 (1.312 sec/step)
1215 85:50:00.719158 12444 learning.py:512] global step 274993: loss = 2.4774 (1.312 sec/step)
INFO:tensorflow:global step 274994: loss = 2.4676 (1.312 sec/step)
1215 85:50:02.031562 12444 learning.py:512] global step 274994: loss = 2.4676 (1.312 sec/step)
INFO:tensorflow:global step 274995: loss = 2.1764 (1.312 sec/step)
1215 85:50:03.343968 12444 learning.py:512] global step 274995: loss = 2.1764 (1.312 sec/step)
INFO:tensorflow:global step 274996: loss = 2.1509 (1.297 sec/step)
1215 85:50:04.649775 12444 learning.py:512] global step 274996: loss = 2.1509 (1.297 sec/step)
INFO:tensorflow:global step 274997: loss = 2.0733 (1.266 sec/step)
1215 85:50:05.975424 12444 learning.py:512] global step 274997: loss = 2.0733 (1.266 sec/step)
INFO:tensorflow:global step 274998: loss = 2.5504 (1.328 sec/step)
1215 85:50:07.265587 12444 learning.py:512] global step 274998: loss = 2.5504 (1.328 sec/step)
INFO:tensorflow:global step 274999: loss = 2.1299 (1.297 sec/step)
1215 85:50:08.562371 12444 learning.py:512] global step 274999: loss = 2.1299 (1.297 sec/step)
INFO:tensorflow:global step 275000: loss = 2.8278 (1.312 sec/step)
1215 85:50:09.874796 12444 learning.py:512] global step 275000: loss = 2.8278 (1.312 sec/step)
INFO:tensorflow:Stopping Training.
    
```

Gambar 8. Hasil Proses Training Dengan 275.000 Step

Gambar 8 menunjukkan hasil proses training dengan 275.000 step dengan loss= 2.8278 dengan rata-rata waktu 1.3 detik per stepnya.

3.5. Total Loss

Pada saat proses training berlangsung, seluruh proses dapat terlihat pada tensorboard. Hasil nilai total loss merupakan nilai error yang berasal dari sisa nilai akurasi pada setiap step. Berikut ini adalah grafik total loss dari hasil training yang sudah dilakukan.



Gambar 9. Grafik Total Loss Dengan 275.000 Step

3.6. Hasil Proses Testing

Pada tahap ini dilakukan proses testing atau pengujian terhadap data yang dilakukan proses training sebelumnya. Tahap ini dilakukan untuk mengetahui kemampuan sistem dalam melakukan pendeteksian objek sampah organik dan sampah anorganik. Pengujian akan dilakukan pada setiap step yang telah dilakukan proses training data. Pengujian data dilakukan terhadap 30 gambar jenis sampah organik dan 30 jenis gambar sampah anorganik dan pengujian juga dilakukan menggunakan objek sampah secara langsung dengan jumlah 30 objek jenis sampah organik dan 30 jenis sampah anorganik.

Tabel 4. Confusion Matrix Testing Gambar Dengan 275.000 Step

| Class | Organik | Anorganik |
|-----------|---------|-----------|
| Organik | 29 | 3 |
| Anorganik | 1 | 27 |

Dari tabel 4 di atas maka dapat dihitung nilai akurasi untuk 275.000 step proses training menggunakan rumus sebagai berikut.

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN}$$

$$Akurasi = \frac{29 + 27}{29 + 27 + 3 + 1} = \frac{56}{60}$$

$$Akurasi = 0.93 \times 100$$

$$Akurasi = 93\%$$

Sedangkan untuk 275.000 step proses training hasil precission dan recall dapat dihitung menggunakan rumus sebagai berikut.

$$\begin{aligned} \text{Precision} &= \frac{TP}{TP + FP} = \frac{29}{29 + 3} = \frac{29}{32} \\ \text{Precision} &= 0.90 \times 100 \\ \text{Precision} &= 90\% \\ \text{Recall} &= \frac{TP}{TP + FN} = \frac{29}{29 + 1} = \frac{29}{30} \\ \text{Precision} &= 0.96 \times 100 \\ \text{Precision} &= 96\% \end{aligned}$$

Tabel 5. Confusion Matrix Testing Obejek Real Dengan 275.000 Step

| Class | Organik | Anorganik |
|-----------|---------|-----------|
| Organik | 30 | 2 |
| Anorganik | 0 | 28 |

Dari tabel 5 diata maka dapat dihitung nilai akurasi untuk 275.000 step proses training menggunakan rumus sebagai berikut.

$$\begin{aligned} \text{Akurasi} &= \frac{TP + TN}{TP + TN + FP + FN} \\ \text{Akurasi} &= \frac{30 + 28}{29 + 24 + 6 + 1} = \frac{58}{60} \\ \text{Akurasi} &= 0.966 \times 100 \\ \text{Akurasi} &= 96.6\% \end{aligned}$$

Sedangkan untuk 275.000 step proses training hasil precission dan recall dapat dihitung menggunakan rumus sebagai berikut.

$$\begin{aligned} \text{Precision} &= \frac{TP}{TP + FP} = \frac{30}{30 + 2} = \frac{30}{32} \\ \text{Precision} &= 0.937 \times 100 \\ \text{Precision} &= 93.7\% \\ \text{Recall} &= \frac{TP}{TP + FN} = \frac{30}{30 + 0} = \frac{30}{30} \\ \text{Precision} &= 1 \times 100 \\ \text{Precision} &= 100\% \end{aligned}$$

Tabel 6. Hasil Confusion Matrix

| | Deteksi Gambar | Deteksi Objek Real |
|-----------|----------------|--------------------|
| Akurasi | 93% | 96.6% |
| Precision | 90% | 93.7% |
| Recall | 96% | 100% |

3.7. Prototype Tempat Sampah

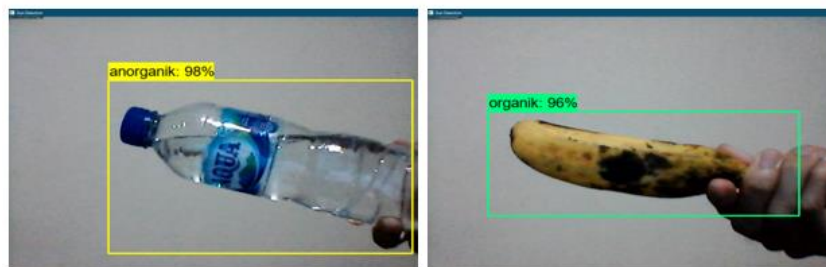
Prototype ini dibuat dengan menggunakan bahan akrilik dengan lebar 40 cm dan tinggi 50 cm. Untuk lebar dibagi menjadi dua bagian untuk jenis sampah organik dan jenis sampah anorganik yang masing-masing lebarnya 20 cm. Gambar 4.19 menunjukkan gambar prototype tempat sampah.



Gambar 10. Prototype Tempat Sampah

3.8. Tampilan Hasil Deteksi

Berikut adalah tampilan hasil deteksi kamera berhasil membaca objek. Kamera ini menjadi mata dari prototype tempat sampah untuk identifikasi jenis sampah. Gambar 11 menunjukkan tampilan hasil deteksi.



Gambar 11. Tampilan Hasil Deteksi

4. KESIMPULAN

Berdasarkan pengujian dalam identifikasi jenis sampah secara otomatis menggunakan Convolutional Neural Network (CNN) yang telah dilakukan, hasil penelitian ini dapat disimpulkan bahwa :

1. Identifikasi jenis sampah menggunakan Convolutional Neural Network (CNN) dapat membantu untuk menentukan jenis sampah dengan inputan gambar dan menghasilkan akurasi dengan 275.000 step sebesar 93% dan untuk inputan gambar secara realtime menghasilkan akurasi untuk dengan 275.000 sebesar 96.6%.
2. Inputan objek secara realtime menghasilkan akurasi yang lebih baik dibandingkan dengan inputan gambar.
3. Convolutional Neural Network dengan arsitektur SSD MobileNetV2 dapat diproses melalui Jetson Nano.

DAFTAR PUSTAKA

- [1] Abror, Z. F. (2019) 'Klasifikasi Citra Kebakaran Dan Non Kebakaran Menggunakan Convolutional Neural Network', *Jurnal Ilmiah Teknologi dan Rekayasa*, 24(2), pp. 102–113. doi: 10.35760/tr.2019.v24i2.2389.
- [2] Budiarto, Widodo. 2016. *Machine Learning & Computational Intelligence*. Yogyakarta: C.V ANDI OFFSET.
- [3] Aningtiyas, Sumin, W. (2020) 'Pembuatan Aplikasi Deteksi Objek Menggunakan TensorFlow Object Detection API dengan Memanfaatkan SSD MobileNet V2 Sebagai Model Pra-Terlatih', *Jurnal Ilmiah Komputasi*, 19(September), pp. 421–430.
- [4] Eka Putra, W. S. (2016) 'Klasifikasi Citra Menggunakan Convolutional Neural Network (CNN) pada Caltech 101', *Jurnal Teknik ITS*, 5(1). doi: 10.12962/j23373539.v5i1.15696.
- [5] Fadlia, N. and Kosasih, R. (2019) 'Klasifikasi Jenis Kendaraan Menggunakan Metode Convolutional Neural Network (Cnn)', *Jurnal Ilmiah Teknologi dan Rekayasa*, 24(3), pp. 207–215. doi: 10.35760/tr.2019.v24i3.2397.
- [6] Fantara, F. P., Syauqy, D. and Setyawan, G. E. (2018) 'Implementasi Sistem Klasifikasi Sampah Organik dan Anorganik dengan Metode Jaringan Saraf Tiruan Backpropagation', *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer (J-PTIIK) Universitas Brawijaya*, 2(11), pp. 5577–5586.
- [7] Fonda, H. (2020) 'Klasifikasi Batik Riau Dengan Menggunakan Convolutional Neural Networks (Cnn)', *Jurnal Ilmu Komputer*, 9(1), pp. 7–10. doi: 10.33060/jik/2020/vol9.iss1.144.
- [8] Leonardo, L., Yohannes, Y. and Hartati, E. (2020) 'Klasifikasi Sampah Daur Ulang Menggunakan Support Vector Machine Dengan Fitur Local Binary Pattern', *Jurnal Algoritme*, 1(1), pp. 78–90. doi: 10.35957/algoritme.v1i1.440.
- [9] Mulyadi, S., Budiraharjo, R. and Santoso, H. (2019) 'Penerapan Model Convolutional Neural', *Departemen Teknik Elektro dan Teknologi Informasi, FT UGM*, pp. 24–25.
- [10] Nugroho, umar, F. (2021) 'KLASIFIKASI BOTOL PLASTIK MENGGUNAKAN MULTICLASS SUPPORT VECTOR INFO ARTIKEL Diajukan : Diterima : Diterbitkan : Klasifikasi Botol Plastik Menggunakan', *Jurnal Khatulistiwa Informatika*, 9(2), pp. 79–85.
- [11] Nissa Hanum, Miftahul Hasanah. 2020. *Deteksi Objek Dengan Pengenalan Karakter Plat Nomor Kendaraan Indonesia Berbasis Python*. Bandung: Kreatif Industri Nusantara.
- [12] Nugroho, P. A., Fenriana, I. and Arijanto, R. (2020) 'Implementasi Deep Learning Menggunakan Convolutional Neural Network (Cnn) Pada Ekspresi Manusia', *Algor*, 2(1), pp. 12–21.
- [13] Pangestu, Rahmat, A. (2020) 'Implementasi Algoritma CNN untuk Klasifikasi Citra Lahan dan Perhitungan Luas', *Informatika dan Sistem Informasi*, 1(1), pp. 166–174.
- [14] Peryanto, A., Yudhana, A. and Umar, R. (2020) 'Klasifikasi Citra Menggunakan Convolutional Neural Network dan K Fold Cross Validation', *Journal of Applied Informatics and Computing*, 4(1), pp. 45–51. doi: 10.30871/jaic.v4i1.2017.
- [15] Pratama, I. N., Rohana, T. and Mudzakir, T. Al (2020) 'PENGENALAN SAMPAH PLASTIK DENGAN MODEL CONVOLUTIONAL NEURAL NETWORK', *Conference on Innovation and Application of Science and Technology (CIASTECH 2020)*, (Ciastech), pp. 691–698.

- [16] Ramba, L. S. (2020) 'Design Of A Voice Controlled Home Automation System Using Deep Learning Convolutional Neural Network (DL-CNN)', *Telekontran : Jurnal Ilmiah Telekomunikasi, Kendali dan Elektronika Terapan*, 8(1), pp. 57–73. doi: 10.34010/telekontran.v8i1.3078.
- [17] Stephen, Raymon and Santoso, H. (2019) 'APLIKASI CONVOLUTION NEURAL NETWORK UNTUK MENDETEKSI JENIS-JENIS SAMPAH', *Explore – Jurnal Sistem Informasi dan Telematika*, 10.
- [18] Zainuri, M. and Pamungkas, D. P. (2020) 'Implementasi CNN untuk Klasifikasi Bunga Anggrek.pdf', *Seminar Nasional Inovasi Teknologi*, pp. 87–92.