PENGENALAN SAMPAH PLASTIK DENGAN MODEL *CONVOLUTIONAL NEURAL NETWORK*

Irfan Nugraha Pratama [1*)], Tatang Rohana[1)], Tohirin Al Mudzakir[1)]
[1)] Teknik Informatika, Universitas Buana Perjuangan Karawang, Karawang
*Email Korespondensi : if16.irfanpratama@mhs.ubpkarawang.ac.id

ABSTRAK

Edukasi tentang sampah yang rendah serta kultur lingkungan dan keluarga menjadi faktor yang mempengaruhi tingkat kepedulian masyarakat terhadap sampah, tercatat 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. Untuk itu, peneliti mencoba untuk mengimplementasikan metode Convolutional Neural Network (CNN) untuk mengklasifikasikan jenis sampah plastik (anorganik). Metode CNN digunakan karena pada penelitian sebelumnya mendapat akurasi sebesar 95%. Pada penelitian yang dilakukan, peneliti menguji setiap model yang disimpan saat proses pelatihan dan mendapatkan nilai akurasi sebesar 80% pada penyimpanan model ke 6000 dengan nilai rata-rata kerugian mencapai 0,03 dengan pembagian dataset untuk pelatihan sebesar 80% dan 20% untuk pengujian.

Kata kunci: CNN, *Computer Vision*, Klasifikasi, Pengenalan, Sampah

ABSTRACT

Education about low waste and environmental and family culture are factors that influence the level of public awareness of waste. It is recorded that 72% of Indonesians do not care about waste problems. In fact, the waste problem can be solved at the upstream level if the community carries out the 3R Movement, namely reduce, reuse, and recycle. For this reason, this research tried to implement the CNN Convolutional Neural Network (CNN) method to classify types of plastic (inorganic) waste. The CNN method was used because in previous studies it had an accuracy of 95%. In the research conducted, the researcher tested each model that was stored during the training process and got an accuracy value of 80% in the 6000th model storage with an average loss value of 0.03 with the distribution of the dataset for training by 80% and 20% for testing.

Keywords: CNN, Computer Vision, Classification, Patern Recognition, Trash

PENDAHULUAN

Sampah merupakan benda yang berbentuk padat maupun tidak padat yang sudah tidak terpakai dari hasil aktivitas makhlik hidup [1]. Di kawasan Asia Timur, Indonesia memproduksi 187,2 juta ton sampah yang berakhir ke laut sehingga menjadikan Indonesia negara penghasil sampah terbesar kedua setelah Tiongkok. Kultur lingkungan dan budaya serta rendahnya edukasi tentang sampah terhadap masyarakat menjadi factor utama yang mambuat rendahnya kepedulian 72% masyarakat Indonesia terhadap sampah. Padahal, jika masyarakat menerapkan gerakan 3R *reuse, reduce,* dan *recycle* permasalahan sampah dapat diselesaikan sampai level hulunya [2]. Pada tahun 2025 produksi sampah di Indonesia akan mencapai 130.000 ton per hari, hal ini terjadi karena tingkat kepadatan penduduk sebanding dengan tingginya tingkat konsumsi yang menghasilkan sampah [3].

Pada dataset tertentu, akurasi *Convolutional Neural Network* (CNN) dapat menyaingi manusia dalam pengenalan citra [4]. Metode CNN membantu *computer vision* dalam mengambil keputusan, awalnya dimulai dengan LeNet pada tahun 1998, pada tahun 2012 LeNet berkembang menjadi AlexNet dengan tingkat kesalahan sebesar 15,3%. Kemudian pada akhir tahun 2015 ResNet hadir dengan tingkat kesalahan yang lebih rendah yaitu

ISSN Cetak : 2622-1276
ISSN Online : 2622-1284

menghasilkan tingkat kesalahan hanya 3,6% [5] Pada tahun 2019 CNN dengan model *supervised learning* mendapatkan nilai akurasi sebesar 99,95% untuk mengklasifikasi sampah [6].

Untuk membantu 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 persis seperti mata manusia karena sistem kerja mata dan otak manusia belum sepenuhnya dipahami [7, 8]. Pada penelitian ini akan mencoba mengenali sampah menggunakan model *unsupervised learning* CNN.

METODE PENELITIAN

Gambaran Umum Penelitian

Metode penelitian merupakan suatu cara yang ditempuh untuk melakukan penelitian. Pada penelitian kali ini akan menerapkan model *Convolutional Neural Network* (CNN) untuk pengenalan sampah plastik. Alur gambaran umum penelitian dapat dilihat pada Gambar 1.

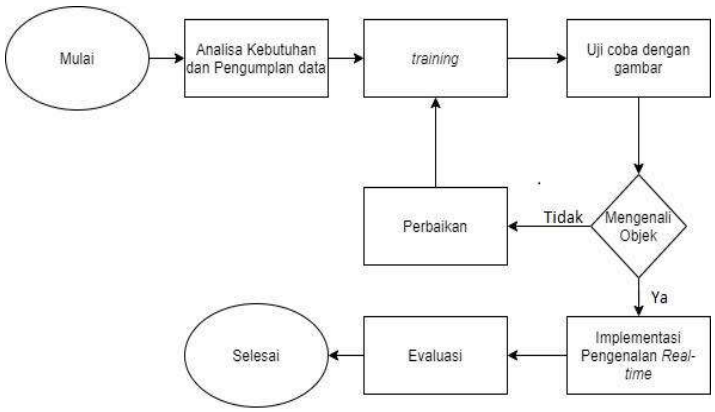

Gambar 1. Gambaran Umum Penelitian

Pengumpulan Data

Data yang dikumpulkan berupa gambar dengan format .jpg yang diambil menggunakan kamera *smartphone* dengan resolusi kamera 13 *megapixel* (MP) yang kemudian diberi *anotasi* untuk mendapatkan koordinat objek yang akan dilatih, ditunjukan pada Gambar 2.

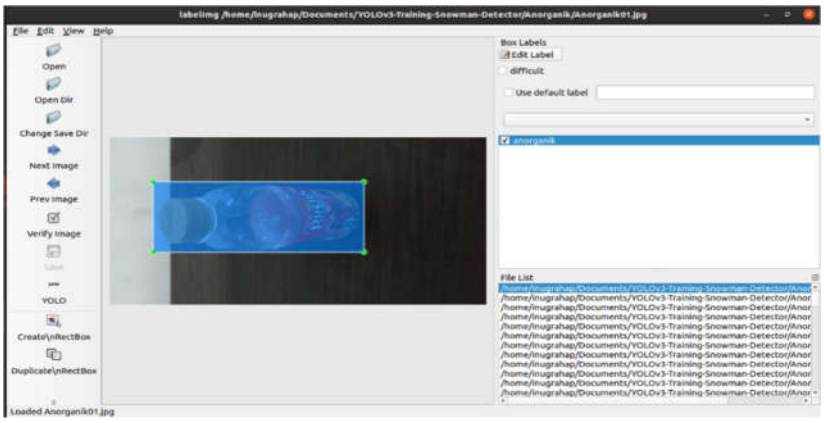

Gambar 2. Anotasi Gambar

Setelah koordinat objek didapatkan, selanjutnya dibagi untuk data pelatihan dan data pengujian dengan perbandingan 80% dan 20%.

Algoritma CNN

CNN merupakan metode yang mengubah setiap lapisan citra asli dari nilai piksel citra menjadi skor yang digunakan untuk klasifikasi karena setiap lapisan ada yang memiiki *hyperparameter* dan ada pula yang tidak memiliki parameter [9]. Model CNN terdiri dari beberapa lapisan konvolusi diikuti oleh fungsi aktivasi dan lapisan penyatuan, dan beberapa lapisan yang terhubung sepenuhnya sebelum prediksi. CNN datang ke struktur yang dalam untuk memfasilitasi mekanisme penyaringan dengan melakukan konvolusi dalam peta fitur skala banyak, yang mengarah ke fitur yang sangat abstrak dan diskriminatif.

Pengujian

Pengujian dilakukan untuk mengetahui apakah penerapan metode CNN model *unsupervised learning* mendapatkan nilai akurasi yang baik untuk pengenalan sampah plastic dengan cara menunjukan objek didepan kamera yang sudah terhubung dengan model CNN.

Evaluasi

Evaluasi hasil dilakukan agar mengetahui akurasi dari model dan juga hasil dari pengenalan gambar. Hal ini dilakukan agar mengetahui tingkat keberhasilan dari model dalam mengenali gambar sampah anorganik. Evaluasi dihitung menggunakan persamaan berikut:

$$\text{Akurasi} = \frac{TP + TN}{TP + TN + FP + FN} \times 100 \quad (1)$$

Pada persamaan (1) dijelaskan bahwa nilai akurasi didapatkan apabila sampah plastik dideteksi sistem sebagai sampah plastik, maka akan dikelompokan sebagai TP (*True Positive*) karena hasil pengenalan sesuai dengan hasil yang diharapkan. Pengelompokan ini dilandaskan dari hasil pengenalan yang menunjukan betul sampah plastik (*True*) dan hasil pengenalan sesuai dengan seharusnya (*Positive*). jika objek yang tidak merupakan sampah plastik (anorganik) dikenali sebagai sampah plastik, akan dimasukan kedalam kelompok FP (*False Positive*), karena pengenalan objek tidak sesuai dengan apa yang diharapkan. Pengelompokkan berdasarkan hasil pengenalan objek mengenali sampah plastik (anorganik), padahal objek yang dikenali bukanlah sampah plastik (anorganik). Ketika objek sampah plastik (anorganik) dideteksi sebagai bukan sampah plastik (anorganik), maka akan dikelompokkan sebagai *False Negative* (FN). Jika model mengenali objek bukan sampah plastik (anorganik) sebagai bukan sampah plastik (anorganik), maka akan dimasukan kedalam kelompok TN (*True Negative*). Pengelompokan ini didasarkan pada model yang mengenali objek bukan sampah plastik (anorganik) sebagai bukan sampah plastik (anorganik), sehingga dianggap *true*, karena yang dikenali bukan termasuk sampah plastik, maka dianggap *negative*.

HASIL DAN PEMBAHASAN

Pengumpulan Gambar

Gambar 3 Hasil Pengambilan Gambar

ISSN Cetak : 2622-1276
ISSN Online : 2622-1284

Dataset yang dikumpulkan untuk penelitian ini adalah gambar yang diambil menggunakan kamera *handphone* Xiaomi redmi note 5 dengan resolusi 13 MP (Megapiksel) yang menghasilkan gambar dengan format (*.jpg). Gambar yang diambil berjumlah 300 gambar, dengan rincian 88 gambar botol plastik (anorganik), 57 gambar gelas plastik (anorganik), dan 61 gambar kantong plastik (anorganik), serta 94 gambar yang bukan termasuk objek penelitian kemudian disimpan dalam satu folder "*Images*".

Anotasi Gambar

Anotasi Gambar dilakukan untuk mendapatkan koodrinat objek yang akan dilatih, berikut hasil anotasi gambar ditunjukan pada Tabel 1.

Tabel 1. Hasil Anotasi Gambar

Object Class Id	***Center-X***	***Center-y***	***Width***	***Height***
1	0.403846	0.537260	0.274038	0.536058
1	0.424279	0.500000	0.266827	0.365385
1	0.383413	0.539663	0.185096	0.237981
.				
.				
.				
0	0.408654	0.534856	0.293269	0.257212
0	0.492788	0.673077	0.283654	0.331731
0	0.375000	0.640625	0.168269	0.65625

Format <*Object Class Id*> <*center-x*> <*center-y*> <*Width*> <*Height*> yang mendefinisikan kelas dan koordinat objek yang akan dilatih setiap barisnya. Pembuatan label pada gambar dilakukan dengan menggunakan aplikasi LabelImg (Tzutalin, 2015) yang disimpan dalam bentuk *file* (*.txt) didalam folder yang sama dengan *file* gambar disimpan yaitu folder "*Images*".

Split Dataset

Split dataset membagi secara acak citra yang telah dikumpulkan dengan 80% *data training* dan 20% *data testing* yang berisikan lokasi penyimpanan citra kemudian hasil *split dataset* disimpan dengan nama "anorganik_train" dan "anorganik_test" dengan format (.txt). Hal ini dilakukan untuk menghindari *overfitting*, sehingga model masih bisa memprediksi cukup akurat walaupun diberikan dataset yang hampir mirip.

Pelatihan Dataset

Dataset citra yang telah dikumpulkan dan diberi pelabelan kemudian dilatih untuk mendapatkan model yang nantinya digunakan pada program pengenalan, terdapat sejumlah parameter yang perlu diperhatikan pada *output* pelatihan, ditunjukan pada Gambar 4

```
Region 106 Avg IOU: -nan, Class: -nan, Obj: -nan, No Obj: 0.000003, .5R: -nan, .75R: -nan,  count: 0
Region 82 Avg IOU: 0.679407, Class: 0.761224, Obj: 0.863997, No Obj: 0.003067, .5R: 1.000000, .75R: 0.000000,  count: 4
Region 94 Avg IOU: 0.766464, Class: 0.999842, Obj: 0.241336, No Obj: 0.000129, .5R: 1.000000, .75R: 1.000000,  count: 1
Region 106 Avg IOU: -nan, Class: -nan, Obj: -nan, No Obj: 0.000003, .5R: -nan, .75R: -nan,  count: 0
Region 82 Avg IOU: 0.629612, Class: 0.992921, Obj: 0.434871, No Obj: 0.001892, .5R: 0.666667, .75R: 0.333333,  count: 3
Region 94 Avg IOU: 0.728052, Class: 0.999625, Obj: 0.430261, No Obj: 0.000146, .5R: 1.000000, .75R: 0.000000,  count: 1
Region 106 Avg IOU: -nan, Class: -nan, Obj: -nan, No Obj: 0.000004, .5R: -nan, .75R: -nan,  count: 0
1101: 0.534947, 0.534947 avg, 0.001000 rate, 10.086932 seconds, 70464 images
```

Gambar 4. *Output* Pelatihan

Skala wilayah

Skala wilayah merupakan perwakilan dari berbagai ukuran parameter pada pelatihan model, terdapat tiga (3) wilayah besar dalam keluaran pada pelatihan *dataset* yaitu *Region 82* yang menggunakan *mask* lebih besar tetapi dapat memprediksi objek yang lebih kecil, kemudian *Region 94* dengan skala prediksi yang tidak besar maupun kecil tetapi menengah dan menggunakan *mask* yang sedang, setelah itu ada *Region 106* yang menggunakan *mask* kecil tetapi dapat memprediksi objek dengan skala yang lebih besar.

Parameter yang dihimpun pada setiap wilayah

Beberapa parameter yang dihimpun oleh skala wilayah yang besar diantaranya meliputi *Region Avg IOU* yang menunjukan rata-rata yang sedang berlangsung, *Class* yang menandai tingkat benar yang mengharapkan nilai yang mendekati 1, *Obj* nilai yang lebih mendekati dengan 1 maka semakin baik, *No Obj* semakin kecil nilai yang didapat maka lebih baik tetapi tidak nol, *.5R* merupakan rasio sampel positif yang ditentukan dalam perhitungan yang sedang berlangsung dengan sampel positif pada semua subdivisi gambar serta nilai positif yang terdeteksi harus 1, *Count* merupakan jumlah gambar dengan sampel positif pada semua subdivisi gambar.

Output batch

```
1101: 0.534947, 0.534947 avg, 0.001000 rate, 10.086932 seconds, 70464 images
```

Gambar 5. *Output Batch*

Output Batch memberitahukan banyaknya iterasi yang sudah dilakukan untuk pelatihan dataset, penurunan nilai kerugian serta rata-rata kerugian saat pelatihan dataset, kecepatan pembelajaran program, dan banyaknya gambar yang dilatih. Berikut penjelasan tentang *output batch* pada Gambar 5:

a. 1101 menunjukan jumlah iterasi yang sedang dilakukan untuk pelatihan.
b. 0.534947 menunjukan keseluruhan nilai kerugian.
c. 0.534947 avg menunjukan nilai rata-rata kerugian. semakin kecil nilainya maka semakin baik, setidaknya saat nilai rata-rata kerugian sudah mencapai 0.060730 atau lebih kecil, pelatihan sudah dapat dihentikan.
d. 0.001000 *rate* merupakan kecepatan model dalam pembelajaran.
e. 10.086932 *second* merupakan waktu yang telah ditempuh dalam proses pembelajaran.
f. 70464 *images* merupakan banyaknya gambar yang sudah dihitung saat proses pembelajaran sedang berjalan.

Hasil Pelatihan

Dari pelatihan data yang dilakukan sebanyak 6000 iterasi, didapatkan hasil dengan nilai kerugian sebesar 0,03 walaupun pelatihan dapat dihentikan saat nilai kerugian mencapai 0,06 [10].

Hasil Pengujian

Pengujian yang dilakukan bertujuan untuk mengetahui tingkat akurasi pada model yang telah dibuat. Pengujian dilakukan dengan membandingkan tingkat akurasi model pada setiap *chehckpoint* penyimpanan mulai dari iterasi ke 1000 hingga iterasi ke 6000 sebanyak 30 kali. Perbedaan akurasi dari setiap model yang disimpan ditunjukkan pada Tabel 2.

ISSN Cetak : 2622-1276
ISSN Online : 2622-1284

Tabel 2 Hasil Pengujian

No	Objek ke-	Iterasi					
		1000	2000	3000	4000	5000	6000
1	Objek 1	TP	TP	TP	TN	TP	TP
2	Objek 2	TN	TP	TP	TP	TP	TP
3	Objek 3	TN	TP	TN	TP	FP	TN
4	Objek 4	TP	FN	FP	TP	TP	TN
5	Objek 5	TN	TP	TP	TP	TP	FP
. . .							
30	Objek 30	TN	TP	FP	TP	TP	TP
Hasil Akurasi		20%	66.67%	73.33%	73.33%	80%	80%

Pengujian pada iterasi 5000 menunjukan nilai akurasi sebesar 80% karena pada iterasi ini nilai kerugian yang didapatkan lebih kecil dari 0,06.

KESIMPULAN

Pengenalan sampah plastik dengan menggunakan metode Convolutional Neural Network (CNN) dengan menggunakan model *unsupervised learning* mendapatkan nilai akurasi sebesar 80% dari iterasi pelatihan ke 5000 dengan nilai kerugian pelatihan lebih kecil dari 0,06. Gunakan model *supervised learning* Agar mendapatkan nilai akurasi yang lebih baik seperti pada penelitian sebelumnya.

UCAPAN TERIMA KASIH

Naskah ilmiah ini adalah sebagian dari penelitian Tugas Akhir milik Irfan Nugraha Pratama yang dibimbing oleh Tatang Rohana dan Tohirin Al Mudzakir.

REFERENSI

[1] Agus, R. N., Oktaviyanthi, R., and Sholahudin, U. "3R: Suatu Alternatif Pengolahan Sampah Rumah Tangga," Kaibon Abhinaya J. Pengabdi. Masy., vol. 1, no. 2, p. 72, 2019.

[2] Kemenkeu, "Media Keuangan," Kemenkeu, vol. 8, no. 14, p. 002, 2019.

[3] Sarmidi and Bhui, B."Jurnal manajemen dan teknik informatika," Ranc. BANGUN Sist. Inf. Pengolah. BANK SAMPAH PUSPASARI Kec. PURBARATU KOTA TASIKMALAYA, vol. 02, no. 01, pp. 181–190, 2018.

[4] Putra, I. W. S. E., Wijaya, A. Y., and Soelaiman, R. "Klasifikasi Citra Menggunakan Convolutional Neural Network (Cnn) Pada Caltech 101 Image Classfication Using Convolution Neural Network (Cnn) on Caltech 101," Inst. Teknol. Sepuluh Novemb., 2016.

[5] Du, J. "Understanding of Object Detection Based on CNN Family and YOLO Understanding of Object Detection Based on CNN Family and," 2018.

[6] Toğaçar, M., Ergen, B., and Cömert, Z. "Waste Classification using AutoEncoder Network with Integrated Feature Selection Method in Convolutional Neural Network," Measurement, p. 107459, 2019.

[7] Wijaya, T. A., and Prayudi, Y. "IMPLEMENTASI VISI KOMPUTER DAN SEGMENTASI CITRA UNTUK KLASIFIKASI BOBOT TELUR AYAM RAS," Snati 2010, vol. 2010, no. Snati, pp. 1–5, 2010.

[8] Masithoh, R. E., Rahardjo, B., Sutiarso, L., and Hardjoko, A. "PENGEMBANGAN COMPUTER VISION SYSTEM SEDERHANA UNTUK MENENTUKAN KUALITAS TOMAT Development of a simple Computer Vision System to determine tomato quality," Agritech, vol. 31, no. 02, 2012.

[9] M. Zufar, "Convolutional Neural Networks untuk Pengenalan Wajah Secara Real - Time," vol. 5, no. 2, pp. 72–77, 2016.

[10] Nayak, S. "Training YOLOv3 : Deep Learning based Custom Object Detector OpenCV," Learn OpenCV, 2020. [Online]. Available: https://www.learnopencv.com/training-yolov3-deep-learning-based-custom-object-detector/. [Accessed: 27-Sep-2020].

ISSN Cetak : 2622-1276
ISSN Online : 2622-1284