e-ISSN: 2460-870X | p-ISSN: 2085-1367

Perbandingan Klasifikasi Jenis Sampah Menggunakan *Convolutional Neural Network* Dengan Arsitektur ResNet18 dan ResNet50

The Classification Comparison of Waste Type Using Convolutional Neural Network by Resnet18 and Resnet50 Architecture

Christin Eva Sari Nainggolan[a,1], Muhammad Nasir* [b,2], Fatoni[c,3], Devi Udariansyah[d,4],
[a,b,c,d]Teknik Informatika, Universitas Bina Darma; Jl. Jenderal Ahmad Yani No.3,9/10 Ulu, Kecamatan Seberang Ulu I, Palembang, Sumatera Selatan 30111
nainggolanevasari@gmail.com[1], nasir@binadarma.ac.id*[2], fatoni@binadarma.ac.id[3],
devi.udariansyah@binadarma.ac.id[4]

ABSTRAK

Permasalahan yang kompleks terjadi dalam mengatasi persoalan sampah, di negara berkembang dan negara maju, misalnya Indonesia. Menurut informasi data Kementerian Lingkungan Hidup dan Kehutanan (KLHK), pada tahun 2022 total tumpukan sampah menjangkau angka hingga 34.439.338.12 ton per tahun. Dalam penelitian ini akan digunakan deep learning dengan membandingkan arsitektur CNN yaitu ResNet18 dengan ResNet50 untuk klasifikasi jenis-jenis sampah. Penelitian ini menggunakan data citra sampah sebanyak 2527 gambar yang terdiri dari enam kelas yaitu cardboard, glass, metal, paper, plastic dan trash. Convolutional Neural Network adalah salah satu jenis jaringan syaraf Deep Neural Network yang memiliki kemampuan untuk mengidentifikasi objek dalam gambar dengan tingkat kompleksitas yang tinggi. Proses validasi dilakukan dengan membagi data menjadi dua set, yaitu data pelatihan (train) dan data pengujian (test). Setelah model dilatih menggunakan data pelatihan, kami menggunakan data pengujian untuk mengukur performa model dengan menghitung metrik seperti akurasi, presisi, dan recall. Dari uji coba model ResNet18 dalam penelitian ini menghasilkan akurasi sebesar 98.69% dan hasil uji coba pada ResNet50 menghasilkan akurasi sebesar 99.41%. Hasil precision dan recall dari kedua model mencerminkan performa yang sangat baik serta akurasi sekitar 99%. Sehingga dapat disimpulkan bahwa kedua model CNN yaitu ResNet18 maupun ResNet50, memiliki kinerja yang sangat baik dalam melakukan klasifikasi citra sampah.

Kata Kunci : Garbage classification, Convolutional Neural Network (CNN), ResNet18, ResNet50.

ABSTRACT

Complex problems occur in overcoming waste issues, in developing and developed countries, such as Indonesia. According to data information from the Ministry of Environment and Forestry, in 2022 the total amount of waste will reach up to 34,439,338.12 tons per year. In this research, deep learning will be used by comparing CNN architecture, namely ResNet18 with ResNet50 for the classification of waste types. This study uses 2527 images of garbage image data consisting of six classes namely cardboard, glass, metal, paper, plastic and trash. Convolutional Neural Network is one type of Deep Neural Network that has the ability to identify objects in images with a high level of complexity. The validation process is carried out by dividing the data into two sets, namely training data (train) and test data (test). After the model is trained using the training data, we use the test data to measure the performance of the model by calculating metrics such as accuracy, precision, and recall. From the ResNet18 model test in this study, the accuracy was 98.69% and the test results on ResNet50 resulted in an accuracy of 99.41%. The precision and recall results of both models reflect excellent performance and accuracy of around 99%. So it can be concluded that both CNN models, namely ResNet18 and ResNet50, have excellent performance in classifying waste images.

Keywords : Garbage Classification, Convolutional Neural Network (CNN), ResNet18, ResNet50.

Info Artikel :
Disubmit: *Direview:* *Diterima :*

Copyright © 2022 – CSRID Journal. All rights reserved.

1. PENDAHULUAN

Limbah merupakan benda atau objek yang tidak lagi dianggap berguna atau tidak lagi diperlukan dalam kerangka produksi, limbah dibuang tanpa pertimbangan serta berpotensi menyebabkan kerusakan pada lingkungan [1].

Jumlah sampah di Indonesia pada tahun 2022 mencapai 34,439,338.12 ton per tahun. Berdasarkan informasi dari Kementrian Lingkungan Hidup dan Kehutanan. Laporan Sistem Informasi Pengelolaan Sampah Nasional mengungkapkan bahwa sekitar 35.34% dari total sampah tidak dikelola dengan baik. Hal ini mengindikasikan bahwa kesadaran masyarakat Indonesia terhadap pengelolaan sampah masih kurang memadai.

Salah satu dari varian dari jenis limbah adalah limbah domestik yang terdiri dari sampah yang bersifat anorganik. Jenis sampah ini memiliki potensi dampak negatif yang sangat berbahaya bagi lingkungan dan kesehatan, karena terdiri dari material anorganik yang berasal dari sumber daya alam yang tak dapat diperbaharui dan mengandung komponen kimia. Sayangnya, bahaya limbah anorganik ini seringkali diabaikan. Sampah jenis ini timbul dari komponen non-hayati, baik dalam bentuk produk sintetis maupun sebagai hasil dari proses teknologi yang terkait dengan eksploitasi mineral dan sumber daya alam. Namun, hal ini tidak dapat diurai oleh proses alami. Contohnya mencakup botol plastik, tas plastik, serta kaleng [2].

Selama ini tindakan memilah-milah sampah seringkali dianggap beban, hal yang menekan, dianggap tidak mungkin, merepotkan dan pandangan ini muncul diberbagai keluarga. Ironisnya, meskipun tanpa disadari tindakan memilah sampah sebenarnya sudah dilakukan dilingkungan rumah. Akan tetapi, kenyataannya adalah ketika saatnya membuang sampah, semuanya dicampur menjadi satu, lalu dibuang ke Tempat Pembuangan Akhir (TPA) bahkan dilemparkan ke sungai atau saluran dan bahkan dibakar yang dapat menyebabkan timbulnya berbagai jenis penyakit, pencemaran lingkungan dan kerusakan ekosistem [3].

Hasil penelitian yang dilakukan oleh Sujatmiko dan rekan-rekannya pada tahun 2022 menunjukkan bahwa penggunaan variasi model ResNet, termasuk ResNet18 dan ResNet50, menghasilkan tingkat akurasi yang berbeda-beda [4]. Seiring dengan itu, riset yang dilakukan oleh Uyar dan teman-temannya pada tahun yang sama melakukan perbandingan beragam jaringan yang telah terlatih sebelumnya atau *pre-trained networks*, termasuk ResNet18 dan juga ResNet50, untuk tujuan mengidentifikasi serta mengklasifikasikan gambar. Selain itu, faktor *hyperparameter* seperti tingkat pembelajaran awal atau *initial learning rate*, *minibatch size*, *epoch number*, *filter size*, dan jumlah filter juga terbukti mempengaruhi akurasi dari model CNN [5].

Dalam serangkaian penelitian sebelumnya, berbagai model *Convolutional Neural Network* (CNN) telah dirancang dan dijalankan secara komprehensif untuk mencapai hasil optimal. Dengan cara ini, algoritma tersebut memiliki kemampuan untuk diaplikasikan secara langsung dalam mengimplementasikan proses pemisahan sampah secara otomatis melalui sebuah sistem [6]. Penggunaan

jumlah lapisan konvolusi yang lebih banyak dalam CNN mampu menghasilkan ekstraksi fitur yang lebih kaya, serta sambil mencapai akurasi yang lebih baik [7].

Sebelumnya telah banyak penelitian yang dilaksanakan dalam bidang pengelolaan citra menerapkan model *Convolutional Neural Network* (CNN), penelitian telah berhasil meningkatkan kinerja klasifikasi gambar. Sebagai contoh, dalam riset yang dilakukan oleh Raga Permana dan kawan-kawan, pada tahun 2022, Optimasi *Image Classification* Pada Jenis Sampah Dengan Data *Augmentation* dan *Convolutional Neural Network* mendapat akurasi sebesar 97.99% [8], selanjutnya penelitian tentang Klasifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Metode *Convolutional Neural Network* mampu mencapai akurasi 92% [9]. Kemudian [10] juga melakukan penelitian tentang Klasifikasi Alat Musik Tradisional Papua Menggunakan Metode *Transfer Learning* dan Data Augmentasi dengan nilai akurasi sebesar 98.46%. Penelitian tentang Klasifikasi Motif Citra Batik Solo mendapatkan akurasi sebesar 95% pada proses pengujian yang dilakukan terhadap 745 sampel batik solo [11]. Niswati dkk juga melakukan penelitian yang berjudul, Perbandingan Arsitektur ResNet50 dan ResNet101 dalam Klasifikasi Kanker Serviks pada Citra *Pap Smear*. Hasil dari akurasi ResNet50 yaitu 91% cukup tinggi dan hasil ResNet101 89% [12]. Dari beberapa penelitian–penelitian tersebut dapat disimpulkan bahwa metode CNN mampu mengklasifikasikan citra dengan cukup baik dan dengan hasil yang signifikan.

Convolutional Neural Network (CNN) merupakan salah satu jenis neural *network* yang sudah biasa digunakan pada data *image* dan telah banyak diimplementasikan pada penelitian–penelitian untuk mendeteksi serta mengenali *object* pada sebuah *image* atau gambar.

Berdasarkan berbagai kajian isu dan penelitian sebelumnya, hal tersebut mendorong penulis untuk melakukan perbandingan arsitektur ResNet18 dan ResNet50, yang bertujuan untuk menentukan model arsitektur terbaik untuk klasifikasi jenis sampah. Motivasi utama pembuatan model ResNet adalah untuk menghindari masalah penurunan gradien yang semakin berkurang yang muncul pada CNN [13]. CNN terdiri dari satu atau lebih lapisan yang terhubung penuh, yang biasanya diikuti oleh lapisan subsampling seperti yang biasa terjadi pada jaringan saraf. Seperti pada umumnya jaringan neural, lapisan subsampling diikuti oleh satu atau lebih lapisan yang terhubung penuh [14].

Meskipun penelitian sebelumnya telah menunjukkan keberhasilan penggunaan CNN dalam klasifikasi gambar untuk berbagai aplikasi, termasuk identifikasi sampah, penelitian kami menambahkan kontribusi baru dengan fokus pada perbandingan langsung antara arsitektur ResNet18 dan ResNet50 serta pengaruh faktor *hyperparameter*. Hal ini diharapkan dapat memberikan wawasan yang lebih mendalam tentang pemilihan model dan parameter yang optimal untuk tujuan klasifikasi jenis sampah.

Pada penelitian ini model CNN dibuat menggunakan bantuan library keras dan tensorflow dengan bahasa pemrograman Phyton yang dimuat dalam Google Colaboratory.

2. METODE

Metode yang digunakan dalam penelitian ini ialah metode eksperimen. Metode eksperimen dilakukan pada penelitian ini yaitu dengan mencoba keberhasilan kinerja dari model kemudian membandingkan hasil dari model yang telah dibuat.

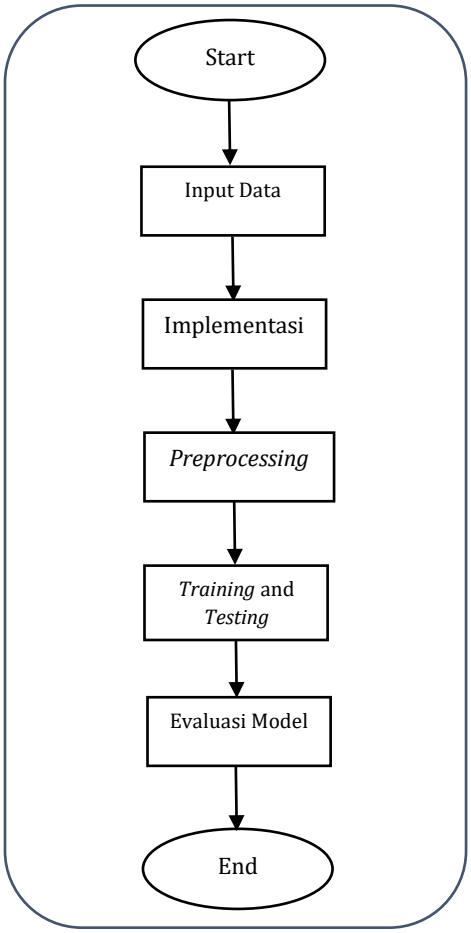
Penelitian ini dimulai dengan mengkaji berbagai literatur, setelah itu langkah berikutnya adalah pengumpulan data yang akan digunakan untuk membuat model CNN. Selanjutnya *dataset* akan di load kedalam Google Colaboratory dan diproses menggunakan bahasa pemrograman python dengan bantuan library tensorflow dan keras.

A. Perancangan Model Penelitian

Penelitian ini akan mengklasifikasikan jenis sampah. Penulis akan menggunakan arsitektur *Convolutional Neural Network* (CNN) dalam penelitian ini, khususnya model ResNet18 dan ResNet50 untuk melakukan tugas klasifikasi jenis sampah. Kemudian penulis akan melakukan perbandingan dari hasil kedua model CNN dalam melakukan klasifikasi gambar sampah.

Gambar 1 rancangan penelitian yang dilakukan, yaitu tahap pertama dengan memasukkan gambar-gambar yang akan diuji, namun sebelum dilakukan pengujian terlebih dahulu dilakukan *split dataset* atau membagi data menjadi subset pelatihan, validasi, dan pengujian. Kemudian data akan di implementasi dan di *preprocessing* termasuk *resize* dan konversi ke tensor dan data dimuat menggunakan pytorch. Tahap selanjutnya *training* yaitu melatih model untuk tahap pengujian. Langkah selanjutnya melibatkan evaluasi untuk menilai performa prediksi dari data latih serta data uji.

DOI: https://www.doi.org/10.22303/csrid.1.1.2022.01-10



Gambar 1. Rancangan Penelitian

B. Pengumpulan Data

Tahap pertama yang dilakukan penulis adalah dengan mengumpulkan *dataset* berupa citra sampah. Adapun data penelitian ini menggunakan data sekunder, yang dikumpulkan dari internet. Data tersebut adalah *garbage classification* yang diunduh dari website kaggle milik CCHANGCS https://www.kaggle.com/*dataset*s/asdasdasasdas/garbage-classification. Pengumpulan data dengan mengunduh data citra sampah atau gambar yang telah dipisah dalam folder tersendiri kemudian data tersebut di upload ke Google Drive dan di load kedalam Google Colaboratory.



Cardboard



Glass



Metal



Paper



Plastic



Trash

Gambar 2. *Dataset* Sampah

C. Data Preprocessing

Preprocessing merupakan langkah yang dilakukan sebelum proses melatih atau menguji model pelatihan citra masukan seperti proses *resize* yaitu *augmentations*, normalisasi, *interpolation*. Tujuan dari proses prapemrosesan adalah untuk menyiapkan data agar siap diproses oleh sistem [15].

```
augmentations = [
            transforms.ColorJitter(brightness=0.5, saturation=0.5, hue=0.5),
            transforms.RandomPerspective(p=1.0),
            transforms.RandomAffine(degrees=0, shear= 25),
            transforms.RandomHorizontalFlip(p=1.0),
            transforms.RandomVerticalFlip(p=1.0),
            transforms.GaussianBlur(kernel_size=7, sigma=(0.1, 5.0))
            ]
rotations = [transforms.RandomRotation(degrees=(x,x), expand=True) for x in range(30,150,30)]
augmentations.extend(rotations)
print("Augmentations Count: ", len(augmentations))
```

Gambar 3. Proses Augmentasi

D. Split Dataset

Sebelum dilakukan perancangan model, tahap selanjutnya dilakukan *split dataset* atau membagi data ke dalam data *training*, data *validation* dan data *testing*. Rancangan jaringan CNN diaplikasikan dengan data *training* untuk melatih model mengenali pola dan membuat prediksi. Validation data berfungsi sebagai pengaturan model selama tahap pelatihan, dan apabila data validasi menghasilkan temuan yang akan memuaskan, dengan demikian, jaringan tersebut dipercaya dalam melaksanakan tugas klasifikasi pada data *testing*. Data dari pengujian digunakan untuk menguji kualitas model yang sudah ditrain. Adapun perbedaan pada *training data*, *validation data* dan *testing data* yaitu 80:10:10 dari 2527 data.

```
#@title
#step 5 Split dataset in training and validation

percentage_of_train = 0.8    # 80% = 0.8
percentage_of_val = 0.5    # 50% = 0.5
```

Gambar 4. *Split* Data

E. Model Desain

Pendekatan pembelajaran mendalam *Convolutional Neural Network* (CNN) digunakan dalam penelitian ini, bersama dengan model ResNet18 dan ResNet50. Setelah melewati *preprocessing*,

DOI: https://www.doi.org/10.22303/csrid.1.1.2022.01-10

selanjutnya akan masuk ke tahap perancangan model dengan ResNet. Pengantisipasian terjadinya *overfitting*, dijalankan melalui penyesuaian *hyperparameter* guna mengontrol proses pelatihan model. *Hyperparameter* yang diatur mencakup *epoch*, *loss function*, *optimizer* dan *batch size*. Lapisan tambahan akan diberi jumlah neuron dan fungsi aktivasi yang disesuaikan untuk keperluan klasifikasi data dalam proses pelatihan.

F. Training and Testing

Pada tahap ini data-data sudah dipisah-pisahkan kedalam data latih dan data pengujian, akan masuk ketahap *training* dan *testing*. Setelah proses pelatihan data selesai langkah berikutnya melibatkan perhitungan akurasi dan *loss* melalui model yang diproduksi saat diuji dengan data yang berbeda. Data pengujian diterapkan guna mengevaluasi tingkat akurasi sebagai hasil oleh model-model sebelumnya pernah ditrain. Penetapan jumlah iterasi atau *epoch* dilakukan dengan cermat untuk mencapai iterasi berulang dalam satu sesi yang menghasilkan kesalahan paling minimal, yang pada gilirannya akan menghasilkan performa yang optimal untuk model yang telah dibuat.

G. Accuracy

Setelah melalui sejumlah tahap proses, model tersebut akan dianalisis melalui perhitungan akurasi dan *loss* menggunakan metode *optimizer* Adam. Pengujian ini akan menggunakan 100 iterasi *epoch*, dengan ukuran *batch* sebesar 32, dan nilai *learning rate* sebesar 0.001.

```
# Observe that all parameters are being optimized
optimizer_ft =  torch.optim.Adam(model_ft.parameters(), lr=0.001)

# Decay LR by a factor of 0.1 every 10 epochs
exp_lr_scheduler =  torch.optim.lr_scheduler.StepLR(optimizer_ft, step_size=10, gamma=0.1)

EPOCHS = 100
```

Gambar 5. Uji Akurasi

Dengan menjalankan 100 kali *epoch* kali iterasi *epoch*, berikut adalah hasil akurasi data validasi yang berhasil dicapai oleh model ResNet18

```
Training complete in 22m 19s
Best val Acc: 0.992063
```

Gambar 6. Hasil Akurasi dari ResNet18

Proses pelatihan berhasil diselesaikan dalam rentang waktu 22 menit 19 detik dengan pencapaian akurasi validasi terbaik mencapai 0.992063 akurasi, dengan nilai *loss* sebesar 0.0486

```
Training complete in 34m 44s
Best val Acc: 0.984127
```

Gambar 7. Hasil Akurasi dari ResNet50

Proses pelatihan pada ResNet50 berhasil diselesaikan dalam rentang waktu 34 menit 19 detik, dengan pencapaian akurasi validasi terbaik mencapai 98.41% akurasi, dengan *loss* sebesar 0.0812.

Pada uji akurasi dari kedua model diatas, ResNet18 lebih unggul karena memiliki kinerja yang lebih baik dalam hal akurasi validasi dan waktu pelatihan yang lebih singkat dibandingkan dengan Model ResNet50.

H. Precision Recall

Tahap *precision* dalam *classification report* adalah salah satu dari beberapa metrik evaluasi klasifikasi yang mengukur sejauh mana model dapat mengidentifikasi secara akurat kelas positif dari semua prediksi yang dilakukan untuk kelas tersebut.

I. Model Evaluation

Untuk mengamati prediksi hasil melalui data pelatihan dan data uji, informasi disajikan dengan bantuan *Confusion matrix*. Model yang telah di-*train* akan diuji menggunakan data uji yang merupakan kumpulan *dataset* yang telah digabungkan. Kemudian penulis akan melakukan analisa terhadap *output* dan kinerja dari kedua model berdasarkan skenario yang telah dilakukan. Kemudian penulis akan membandingkan kedua hasil keluaran model dari model ResNet18 dan ResNet50.

3. HASIL DAN PEMBAHASAN

Penelitian ini membuat model klasifikasi untuk mendeteksi gambar dengan enam kelas yaitu *cardboard*, *glass*, *metal*, *paper*, *plastic*, dan *trash*. Model tersebut dibuat memanfaatkan prosedur CNN dengan dua arsitektur yaitu ResNet18 dengan ResNet50.

Proses pembuatan model klasifikasi ini dilakukan dengan dua langkah utama yaitu, pertama melakukan prosedur pelatihan data yang dimana dilakukan untuk membuat model dan melatih data untuk mengenali dan mempelajari pola yang terdapat di data gambar. Proses ini dilakukan dengan menyusun lapisan-lapisan CNN secara bertahap dan mengatur *hyperparameter* seperti *learning rate*, *batch size*, dan jumlah *epoch*. Selanjutnya, data pelatihan disajikan kepada model untuk dipelajari, di mana model secara bertahap memperbarui bobot dan biasnya berdasarkan kesalahan prediksi terhadap data pelatihan.

Langkah kedua adalah proses pengujian data atau *testing*, yang bertujuan untuk mengevaluasi kinerja model yang telah dibuat. Proses ini dilakukan dengan menggunakan *dataset* pengujian yang terpisah dari *dataset* pelatihan, yang tidak dikenal oleh model sebelumnya. Model kemudian digunakan untuk memprediksi kelas dari gambar-gambar dalam *dataset* pengujian, dan hasil prediksi dibandingkan dengan label sebenarnya untuk menghitung metrik evaluasi seperti akurasi, presisi, *recall*, dan *F1-score*.

A. Dataset

Adapun *dataset* yang digunakan dalam penelitian ini berjumlah 2527 gambar, yang terdiri dari enam kelas yaitu *cardboard* sebanyak 403, *glass* sebanyak 501, *metal* sebanyak 410, *paper* sebanyak 594, *plastic* sebanyak 482 dan *trash* sebanyak 137. Data masukan tersebut berupa foto dengan format .jpg.

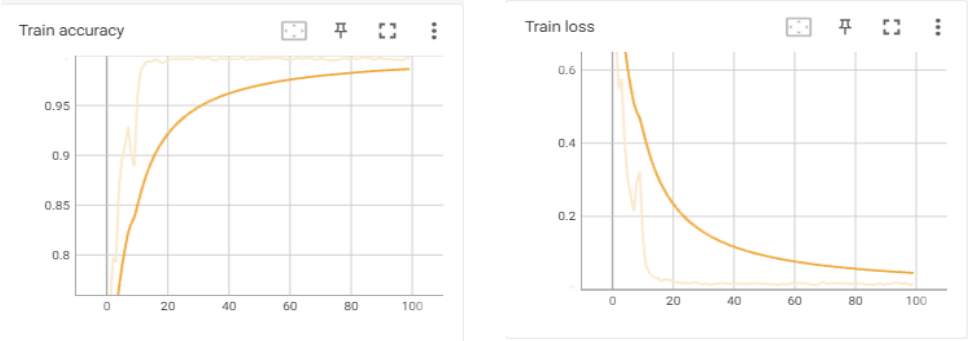
Langkah pertama dalam proses membaca *dataset* adalah menghubungkan Google Drive dengan Google Colab. Pada tahap awal perlu dilakukan pengunggahan *dataset* ke dalam Googe Drive. Berikut hasil dari *dataset* yang berhasil di load ke dalam Google Colab bisa dilihat dibawah ini.

DOI: https://www.doi.org/10.22303/csrid.1.1.2022.01-10

```
['Garbage classification']
Total images carboard  403
Total images glass  501
Total images metal  410
Total images paper  594
Total images plastic  482
Total images trash  137
```

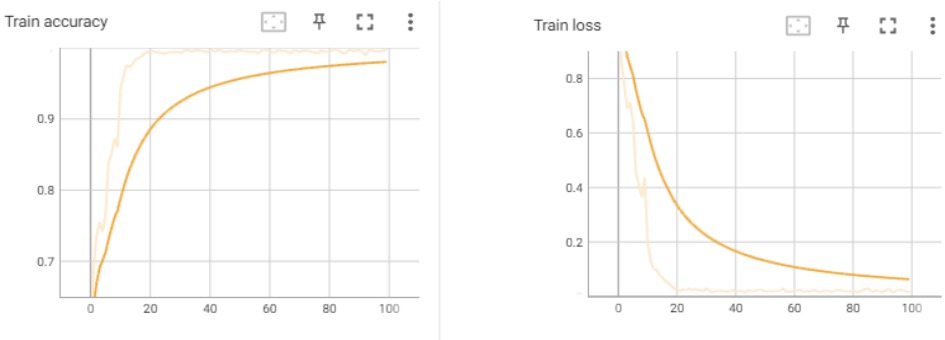
Gambar 8. Total *Dataset* Perkelas

B. Akurasi



Gambar 9. Grafik *Train* Akurasi dan *Loss* dari ResNet18

Dari hasil analisis pada grafik tensor board, dapat diamati bahwa model ResNet-18 akurasi pada *epoch* ke-20 menunjukkan tingkat stabilitas yang baik untuk data pelatihan, dan pola ini berlanjut hingga *epoch* ke-100. Begitu juga hasil dari *train loss*, pada *epoch* ke-20 menunjukkan penurunan dan cukup stabil hinga *epoch* ke-100. Seperti yang diilustrasikan dalam gambar 9.



Gambar 10. Grafik *Train* akurasi dan *loss* dari ResNet50

Sama halnya, dengan model ResNet50, juga mengalami peningkatan pada *epoch* ke-20 dan cukup stabil hingga pada *epoch* ke-100. Pada model ResNet50, terlihat peningkatan akurasi pada *epoch* ke-20 yang kemudian tetap stabil hingga mencapai *epoch* ke-100, seperti yang diilustrasikan dalam gambar 10.

C. Deteksi *Single Image*

http://csr

```
[ ] classes = {0:"cardboard", 1:"glass", 2:"metal", 3:"paper", 4:"plastic", 5:"trash"}
    image_path = "/content/drive/MyDrive/KA Christin/dataset/test/cardboard/cardboard13.jpg"
    image = Image.open(image_path).convert("RGB")
```

Gambar 11. Proses Deteksi *Single Image*

Kode diatas merupakan proses klasifikasi gambar menggunakan model yang terlatih sebelumnya. Pertama didefenisikan kelas-kelas klasifikasi, seperti *cardboard*, *glass*, *metal*, *paper*, *plastic*, dan *trash*. Kemudian gambar dikonversi ke format warna RGB. Selanjutnya gambar diubah menjadi tensor melalui transformasi data yang telah ditentukan sebelumnya, gambar dimuat menggunakan OpenCV dan ditampilkan menggunakan matplotlib.



Gambar 12. Hasil Prediksi Gambar

Gambar 12 merupakan hasil perkiraan pendeteksian per *single image*. Model berhasil memprediksi gambar sesuai dengan kelas yang tepat. Hasil prediksi ini secara akurat menunjukkan bahwa gambar tersebut merupakan jenis "*cardboard"*

D. Precision Recall

Classification Report:

	precision	recall	f1-score	support
cardboard	1.00	1.00	1.00	403
glass	0.99	0.99	0.99	501
metal	1.00	0.99	0.99	410
paper	1.00	1.00	1.00	594
plastic	0.99	0.99	0.99	482
trash	0.99	0.99	0.99	137
accuracy			0.99	2527
macro avg	0.99	0.99	0.99	2527
weighted avg	0.99	0.99	0.99	2527

Gambar 13. *Precision Recall* pada ResNet18

Pada gambar 13 diatas dapat dilihat bahwa *precision* atau tingkat ketepatan dapat menghasilkan yaitu, seperti untuk hasil laporan klasifikasi pada ResNet18 menjelaskan keampuhan model yang digunakan memiliki kinerja yang sangat baik. Tingkat ketepatan atau *precision* seperti pada *cardboard* sebesar 100%, *glass* sebesar 99%, *metal* sebesar 100%, *paper* sebesar 100%, *plastic* sebesar 99%, *trash* sebesar 99%. Adapun untuk tingkat keberhasilan atau *recall* seperti pada cardboard sebesar 100%, glass sebesar 99%, *metal* sebesar 99%, *paper* sebesar 100%, *plastic* sebesar 99%, *trash* sebesar 99%. Setiap kelas *Precision, recall,* dan *f1-score* cukup tinggi, menghasilkan akurasi keseluruhan sekitar 99%.

Classification Report:

	precision	recall	f1-score	support
cardboard	1.00	0.98	0.99	403
glass	0.97	1.00	0.98	501
metal	1.00	0.98	0.99	410
paper	1.00	0.99	0.99	594
plastic	0.98	0.98	0.98	482
trash	0.96	0.99	0.98	137
accuracy			0.99	2527
macro avg	0.98	0.99	0.99	2527
weighted avg	0.99	0.99	0.99	2527

Gambar 14. *Precision Recall* pada ResNet50

Sementara itu, hasil laporan klasifikasi pada ResNet50 menunjukkan bahwa model ResNet50 memiliki performa yang serupa atau bahkan sedikit lebih baik. Tingkat ketepatan atau *precision* seperti pada *cardboard* sebesar 100%, *glass* sebesar 97%, *metal* sebesar 100%, *paper* sebesar 100%, *plastic* sebesar 98%, *trash* sebesar 96%. Adapun untuk tingkat keberhasilan atau *recall* seperti pada *cardboard* sebesar 98%, *glass* sebesar 100%, *metal* sebesar 98%, *paper* sebesar 99%, *plastic* sebesar 98%, *trash* sebesar 99%. Jadi presisi dan *recall* untuk sebagian besar kelas adalah 100%, dengan beberapa kelas memiliki nilai 99%. Ini menghasilkan akurasi keseluruhan sekitar 99%, bahkan kelas dengan presisi paling rendah masih memiliki nilai presisi dan *recall* sekitar 99%.

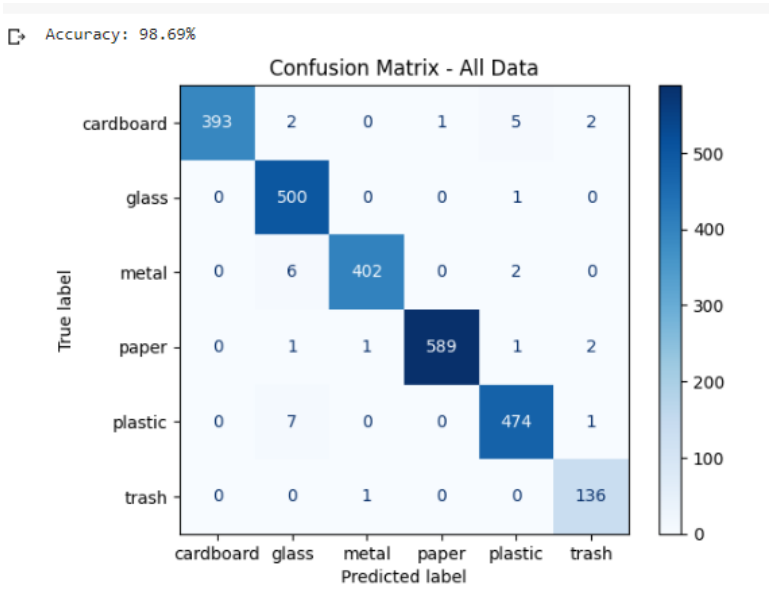
Kedua model memiliki nilai *f1-score* yang sangat baik, menunjukkan kualitas baik dalam menggabungkan presisi dan *recall*. Dalam kedua laporan dari model tersebut nilai untuk rata-rata akurasi *precision*, *recall*, dan *f1-score* juga mencerminkan performa yang sangat baik.

Secara umum, baik model ResNet18 maupun model ResNet50 menunjukkan bahwa mereka memiliki kemampuan yang sangat baik dalam mengklasifikasikan berbagai kelas sampah dalam *dataset*. Dengan presisi, *recall*, dan *f1-score* yang tinggi, serta akurasi keseluruhan sekitar 99%, keduanya adalah pilihan yang baik untuk tugas klasifikasi sampah.

Secara umum, baik model ResNet18 maupun model ResNet50 menunjukkan bahwa mereka memiliki kemampuan yang sangat baik dalam mengklasifikasikan berbagai kelas sampah dalam *dataset*. Dengan presisi, *recall*, dan *f1-score* yang tinggi, serta akurasi keseluruhan sekitar 99%, keduanya adalah pilihan yang baik untuk tugas klasifikasi sampah.

E. Evaluasi dan Prediksi dari Seluruh Kelas

Untuk mengamati hasil pelatihan dan prediksi data uji, informasi tersebut disajikan dalam bentuk *Confusion matrix* diilustrasikan dalam gambar dibawah.

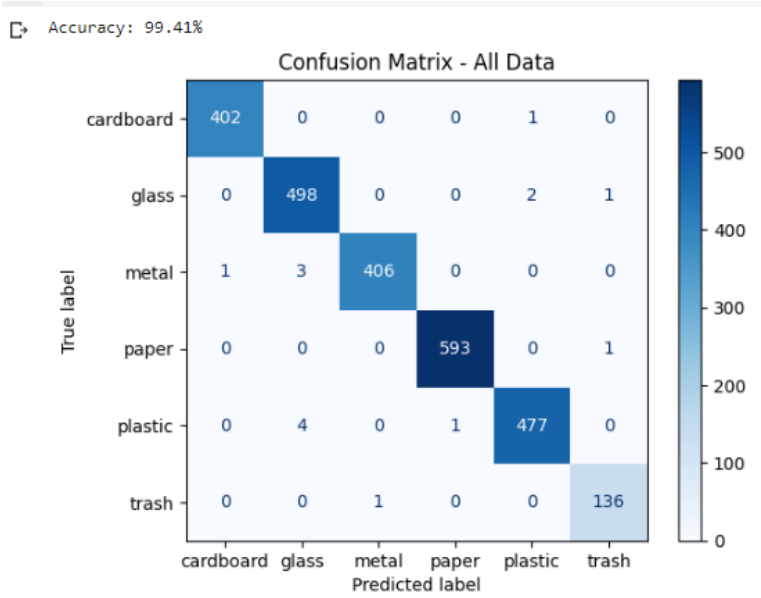


Gambar 15. Hasil Klasifikasi Data Baru Menggunakan ResNet18

Gambar 15 diatas menampilkan hasil perkiraan menggunakan model ResNet18. Dalam total 2527 data gambar sampah yang dimasukkan, model ini berhasil mengklasifikasikan dengan sangat baik. Hasil prediksi tersebut mengungkap bahwa:

1. Untuk kategori "*cardboard*" dari total 403 data, model berhasil mengklasifikasikan 393 data dengan benar, dan 10 data salah diklasifikasikan.
2. Pada kategori "*glass*" dari total 501 data, model berhasil mengklasifikasikan 500 data dengan benar, dan hanya 1 data yang salah diklasifikasikan.
3. Kategori "*metal*" dari total 410 data, dan model berhasil mengklasifikasikan 402 data dengan benar, dan 8 data salah diklasifikasikan.
4. Pada kategori "*paper*" dari total 594 data, model berhasil mengklasifikasikan 589 data dengan benar, dan 5 data salah diklasifikasikan.
5. Kategori "*plastic*" dari total 482 data, model berhasil mengklasifikasikan 474 data dengan benar, dan 8 data salah diklasifikasikan.
6. Terakhir, pada kategori "*trash*" dari total 137 data, model berhasil mengklasifikasikan 136 data dengan benar, dan hanya 1 data yang salah diklasifikasikan.

DOI: https://www.doi.org/10.22303/csrid.1.1.2022.01-10



Gambar 16. Hasil Klasifikasi Data Baru Menggunakan ResNet50

Gambar 16 menampilkan hasil prediksi menggunakan model ResNet50. Dalam total 2527 data gambar sampah yang dimasukkan, model ini juga berhasil mengklasifikasikan dengan sangat baik. Hasil prediksi tersebut mengindikasikan:

1. Kategori "*cardboard*" dari total 403 data, model berhasil mengklasifikasikan 402 data dengan benar, dan hanya 1 data yang salah diklasifikasikan.
2. Pada kategori "*glass*" dari total 501 data, model berhasil mengklasifikasikan 498 data dengan benar, dan 3 data salah diklasifikasikan.
3. Kategori "*metal*" dari total 410 data, model berhasil mengklasifikasikan 406 data dengan benar, dan 4 data salah diklasifikasikan.
4. Kategori "*paper*" dari total 594 data, model berhasil mengklasifikasikan 593 data dengan benar, dan hanya 1 data yang salah diklasifikasikan.
5. Pada kategori "*plastic*", dari total 482 data, model berhasil mengklasifikasikan 477 data dengan benar, dan 5 data salah diklasifikasikan.
6. Terakhir, pada kategori "*trash*" dari total 137 data, model berhasil mengklasifikasikan 136 data dengan benar, dan hanya 1 data yang salah diklasifikasikan.

4. KESIMPULAN

Berdasarkan temuan penelitian ini, memungkinkan untuk menyimpulkan kinerja model ResNet18 sedikit lebih baik dari kinerja model ResNet50 jika dilihat dari waktu pelatihan. Namun jika dilihat dari hasil *testing* dapat disimpulkan bahwa kedua model, baik ResNet18 maupun ResNet50, memiliki kinerja

yang sangat baik dalam melakukan klasifikasi citra sampah. Meskipun ada perbedaan dalam beberapa prediksi yang salah, namun secara keseluruhan, keduanya dapat dianggap sebagai metode yang sangat baik untuk melakukan klasifikasi citra sampah. Melihat akurasi yang didapatkan dari model ResNet18 yaitu sebesar 98.69%, dan akurasi yang didapatkan dari model ResNet50 sebesar 99.41%. Hasil *precision*, *recall,* dan *f1-score* juga tinggi, serta akurasi keseluruhan sekitar 99%, keduanya adalah pilihan yang baik untuk tugas klasifikasi sampah.

Saran untuk studi lebih lanjut dapat mencakup perluasan *dataset* gambar, dan menggunakan nilai *epoch* untuk yang lebih banyak agar akurasi makin meningkat, atau bisa menambah teknik di *prepocessing* supaya lebih meningkatkan kualitas dari data citra yang akan di uji, atau juga bisa mencoba membandingkan model selain model ResNet18 dan ResNet50.

REFERENSI

[1] Rima Dias Ramadhani, A. Nur Aziz Thohari, C. Kartiko, A. Junaidi, T. Ginanjar Laksana, and N. Alim Setya Nugraha, "Optimasi Akurasi Metode Convolutional Neural Network untuk Identifikasi Jenis Sampah," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 5, no. 2, pp. 312–318, 2021, doi: 10.29207/resti.v5i2.2754.

[2] N. Marliani, "Pemanfaatan Limbah Rumah Tangga Sbg Implementasi Plh," *J. Form.*, vol. 4, no. 2, pp. 124–132, 2014, [Online]. Available: https://media.neliti.com/media/publications/234976-pemanfaatan-limbah-rumah-tangga-sampah-a-533e820b.pdf

[3] H. H. T. Takbiran, "Bank Sampah Sebagai Alternatif Strategi Pengelolaan Sampah Menuju Sentul City Zero Emission Waste Kabupaten Bogor," *IJEEM - Indones. J. Environ. Educ. Manag.*, vol. 5, no. 2, pp. 165–172, 2020, doi: 10.21009/ijeem.052.05.

[4] B. M. Sujatmiko, E. Yudaningtyas, and P. M. Raharjo, "Convolutional Neural Network Using ResNet Network Design As Skin Tumor Classification Method," vol. 11, no. 1, pp. 53–64, 2022.

[5] K. Uyar, Ş. Taşdemir, and I. A. Özkan, "The analysis and optimization of CNN Hyperparameters with fuzzy tree model for image classification," *Turkish J. Electr. Eng. Comput. Sci.*, vol. 30, no. 3, pp. 961–977, 2022, doi: 10.3906/ELK-2107-130.

[6] Stephen, Raymond, and H. Santoso, "Aplikasi Convolution Neural Network untuk Mendeteksi Jenis-Jenis Sampah," *Explor. – J. Sist. Inf. dan Telemat.*, vol. 10, no. 2, pp. 122–132, 2019.

[7] E. Jing, H. Zhang, Z. Li, Y. Liu, Z. Ji, and I. Ganchev, "ECG Heartbeat Classification Based on an Improved ResNet-18 Model," *Comput. Math. Methods Med.*, vol. 2021, p. 6649970, 2021, doi: 10.1155/2021/6649970.

[8] R. Permana, H. Saldu, and D. I. Maulana, "Optimasi Image Classification Pada Jenis Sampah Dengan Data Augmentation Dan Convolutional Neural Network," *J. Sist. Inf. dan Inform.*, vol. 5, no. 2, pp. 111–120, 2022, doi: 10.47080/simika.v5i2.1913.

[9] I. R. Ramadhani, A. Nilogiri, and A. Qurrota, "Klasifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Metode Convolutional Neural Network Classification Of Plants Based On Leaf Image Using Convolutional Neural Network Method," *J. Smart Teknol.*, vol. 3, no. 3, pp. 2774–1702, 2022, [Online]. Available: http://jurnal.unmuhjember.ac.id/index.php/JST

[10] A. Solihin, D. I. Mulyana, and M. B. Yel, "Klasifikasi Jenis Alat Musik Tradisional Papua

menggunakan Metode Transfer Learning dan Data Augmentasi," *J. SISKOM-KB (Sistem Komput. dan Kecerdasan Buatan)*, vol. 5, no. 2, pp. 36–44, 2022, doi: 10.47970/siskom-kb.v5i2.279.

[11] T. A. Bowo, H. Syaputra, and M. Akbar, "Penerapan Algoritma Convolutional Neural Network Untuk Klasifikasi Motif Citra Batik Solo," *J. Softw. Eng. Ampera*, vol. 1, no. 2, pp. 82–96, 2020, doi: 10.51519/journalsea.v1i2.47.

[12] Z. Niswati, R. Hardatin, M. N. Muslimah, and S. N. Hasanah, "Perbandingan Arsitektur ResNet50 dan ResNet101 dalam Klasifikasi Kanker Serviks pada Citra Pap Smear," *Fakt. Exacta*, vol. 14, no. 3, p. 160, 2021, doi: 10.30998/faktorexacta.v14i3.10010.

[13] S. F. Tumewu, D. H. Setiabud, and I. Sugiarto, "Klasifikasi Motif Batik menggunakan Metode Deep Convolutional Neural Network dengan Data Augmentation," *J. Infra*, vol. 8, no. 2, pp. 189–194, 2020.

[14] H. Fonda, "Klasifikasi Batik Riau Dengan Menggunakan Convolutional Neural Networks (Cnn)," *J. Ilmu Komput.*, vol. 9, no. 1, pp. 7–10, 2020, doi: 10.33060/jik/2020/vol9.iss1.144.

[15] F. F. Maulana and N. Rochmawati, "Klasifikasi Citra Buah Menggunakan Convolutional Neural Network," *J. Informatics Comput. Sci.*, vol. 1, no. 02, pp. 104–108, 2020, doi: 10.26740/jinacs.v1n02.p104-108.