

# Klasifikasi Jenis Sampah Menggunakan Base ResNet-50

Jihan Nuari Putri, Maimunah dan Pristi Sukmasetya

Universitas Muhammadiyah Magelang,

Jl. Mayjend Bambang Soegeng, Glagak, Kabupaten Magelang 56172

E-mail : jihan.nuari10@gmail.com, maimunah@unimma.ac.id, pristi.sukmasetya@ummgl.ac.id

## Abstrak

Produksi sampah meningkat sejalan dengan peningkatan jumlah penduduk. Pengelolaan sampah diperlukan untuk mengurangi sampah yang semakin meningkat salah satunya dengan pemilahan jenis-jenis sampah. Namun, masyarakat masih kesulitan dalam melakukan pemilahan sampah sehingga diperlukan teknologi yang membantu dalam memilah sampah agar tercipta pengelolaan sampah yang optimal. Pada penelitian ini, akan digunakan model ResNet-50 sebagai base model untuk melakukan klasifikasi jenis-jenis sampah. ResNet-50 akan dimodifikasi dengan ditambahkan beberapa layer dan fine-tuning untuk mendapatkan hasil yang optimal. Dari hasil penelitian yang membagi jenis-jenis sampah menjadi 7 kelas (cardboard, glass, metal, paper, plastic, trash dan compost) dengan menggunakan parameter batch size sebesar 16, jumlah epoch 18, learning rate sebesar 0.0001 dengan optimizer Adam menghasilkan nilai evaluasi kinerja dengan nilai akurasi mencapai 98.70%. Hasil penelitian ini dapat membantu memilah sampah dengan lebih maksimal.

**Kata kunci** :Sampah, Pengelolaan Sampah, Klasifikasi, ResNet-50, Fine-Tuning

## Pendahuluan

Sampah adalah benda padat hasil dari kegiatan sehari-hari yang sudah tidak bermanfaat bagi penggunaannya [1]. Pengelolaan sampah menjadi masalah serius di Indonesia. Selain pertumbuhan penduduk yang menyebabkan peningkatan sampah dari tahun ke tahun, adanya aktivitas ekonomi dan demografi juga berdampak pada peningkatan sampah [2].

Berdasarkan data yang didapat dari Sistem Informasi Pengelolaan Sampah Nasional (SIPSN) disebutkan bahwa jumlah timbulan sampah di Indonesia mencapai 19,133,324.35 ton/tahun dengan hasil input data dilakukan oleh 171 Kabupaten/kota se-Indonesia pada tahun 2022. Dari jumlah tersebut, sampah yang berhasil ditangani sebesar 49.37% atau sekitar 10,006,105.10 (ton/tahun) dengan sampah terkelola sebesar 66.92% atau sebesar 13,561,288.15 (ton/tahun) dan sampah tidak terkelola sebesar 33.08% atau sebesar 6,705,151.03 (ton/tahun) [3]. Berdasarkan jenis sampahnya, komposisi sampah terbanyak dihasilkan oleh sisa makanan sebesar 40,6% sedangkan berdasarkan sumber sampahnya, komposisi sampah terbanyak dihasilkan oleh rumah tangga sebesar 38,3% [3]. Pengelolaan sampah masih kurang mendapat penanganan yang optimal baik dari pihak masyarakat maupun pemerintah [4]. Umumnya, pada proses pengelolaan sampah akan di-

lakukan pemilahan sampah. Namun, kebanyakan masyarakat masih kesulitan dalam melakukan pemilahan sampah [5]. Kurangnya pemahaman masyarakat akan pemilahan sampah menjadi salah satu faktor penyebab kurang optimalnya pengelolaan sampah sehingga perlu adanya teknologi untuk membantu pemilahan sampah sesuai dengan jenis sampah.

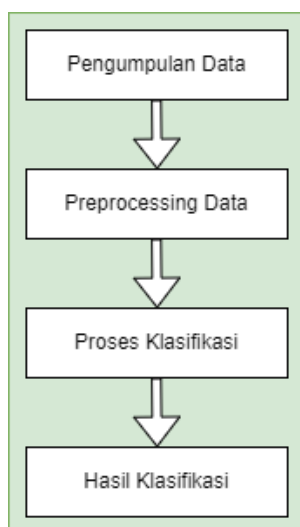
Penelitian mengenai klasifikasi sampah telah banyak dilakukan oleh para peneliti untuk memilah sampah, antaranya dalam Klasifikasi Sampah Daur Ulang Menggunakan Support Vector Machine dengan ekstraksi fitur Local Binary Pattern [6]. Penelitian ini menggunakan dataset TrashNet dengan membagi dataset menjadi 5 kelas yaitu kardus, kaca, logam, kertas dan plastik. Rata-rata akurasi dalam penelitian ini cukup baik mencapai 88,09%.

Penelitian lain terkait klasifikasi sampah adalah klasifikasi sampah menggunakan Convolutional Neural Network [7]. Penelitian ini menggunakan citra sampah sebagai dataset. Citra sampah yang digunakan berupa sampah yang tidak bisa diurai seperti kertas, kaca, metal, sampah, kardus dan plastik yang terdiri lebih dari 100 gambar untuk masing-masing jenis sampah. Penelitian ini menghasilkan akurasi sebesar 92% pada proses training dan 79% pada proses testing.

Selain itu, penelitian lain tentang klasifikasi

sampah yang menerapkan arsitektur Convolutional Neural Network pernah dilakukan dengan hasil bahwa ResNet-50 memiliki kinerja yang lebih baik daripada menggunakan metode lain [8]. Namun, kekurangan yang terdapat pada penelitian tersebut adalah sampah plastik tidak dibagi menjadi beberapa jenis oleh peneliti. Penelitian lain juga pernah mengkomparasikan antara base model ResNet-50, ResNet-50-A (menambah modul CBAM + modifikasi metode downsampling) dan ResNet-50-B (ResNet-50-A + multiscale fusion secara horizontal vertical) untuk klasifikasi sampah [9]. Dataset yang digunakan terbagi menjadi 6 kelas diantaranya glass, cardboard, metal, paper, plastic, dan trash. Nilai akurasi pada penelitian tersebut masing-masing secara berurutan mencapai 84,46%, 88,4% dan 92,08%. Dengan menggunakan jumlah kelas yang sama seperti pada penelitian [9], ResNet-50 pernah digunakan untuk klasifikasi sampah dengan hasil akurasi mendekati 95% dengan nilai epoch 20 [10].

Penelitian selain untuk klasifikasi sampah yang menggunakan ResNet sebagai model dan CNN sebagai klasifikasi pernah dilakukan untuk mengklasifikasi penyakit pada daun gandum yang hasil akurasi tertinggi mencapai 98% [11]. Penelitian lain yang menggunakan ResNet dan CNN adalah untuk klasifikasi sidik jari dengan akurasi pelatihan 99,52% dan akurasi validasi 95,05% [12]. Selain itu, penelitian yang menggunakan ResNet dan CNN juga pernah dilakukan untuk mendeteksi satwa yang dilindungi [13]. Penelitian ini menghasilkan akurasi tertinggi untuk akurasi training mencapai 99,34% sedangkan akurasi tertinggi untuk akurasi testing mencapai 90,43%. Dapat disimpulkan dari hasil tersebut menunjukkan bahwa penggunaan model ResNet dalam klasifikasi cukup optimal dalam memberi akurasi terbaik.



Gambar 1: Alur Metode Penelitian

Dalam penelitian ini akan dilakukan klasifikasi sampah menggunakan ResNet sebagai model dan

CNN sebagai metode klasifikasi dengan harapan mendapatkan pemilahan sampah secara maksimal. Penelitian ini bertujuan untuk membantu pengelolaan sampah yang tepat sehingga tercipta lingkungan yang bersih dan sehat.

## Metode Penelitian

Penelitian ini dilakukan dengan melakukan tahapan yang disajikan dalam bentuk alur metode penelitian pada Gambar 1. Terdapat 4 tahap dalam proses penelitian terhadap klasifikasi sampah yang meliputi pengumpulan data, preprocessing data, proses klasifikasi dan hasil klasifikasi. Berikut adalah penjelasan mengenai alur metode pada penelitian ini.

### Pengumpulan Data

Pada tahap ini data yang dikumpulkan berupa citra dari berbagai macam jenis sampah. Data yang dikumpulkan sebanyak 2751 citra berekstensi .jpg yang terbagi menjadi 7 kelas, diantaranya cardboard, glass, metal, paper, plastic, trash dan compost. Pengumpulan data pada penelitian ini diambil melalui situs Kaggle <https://www.kaggle.com/datasets/haroldobregm/trashclasification>. Data tersebut diupload oleh HozPer dengan nama dataset TrashClasification dan terakhir diperbaharui pada tahun 2021 [14].

### Preprocessing Data

Setelah data terkumpul selanjutnya data citra disiapkan sebelum diolah ke tahap selanjutnya pada preprocessing [15]. Pada penelitian ini tahapan yang dilakukan dalam preprocessing adalah augmentasi data dan membagi data antara data training dan validation. Augmentasi adalah tahap mengolah data dengan memodifikasi data citra [16]. Pada penelitian ini tahap augmentasi yang dilakukan yaitu shearing, zooming dan shifting. Augmentasi data dilakukan pada direktori training untuk menambah keragaman citra dalam data training tanpa penambahan citra baru [17] sehingga mampu menghindari terjadinya overfitting dan menghasilkan kinerja model yang baik [18]. Kemudian kedua direktori baik training maupun validation dilakukan pembagian data menggunakan teknik Split Validation. Split Validation akan membagi data menjadi dua bagian secara acak sesuai dengan perbandingan yang diinginkan.

### Proses Klasifikasi

Model pada penelitian ini dijalankan menggunakan Google Colab dengan bahasa pemrograman menggunakan Python sedangkan library menggunakan Tensorflow Keras. Setelah dilakukan pre-processing data, selanjutnya dilakukan proses klasifikasi menggunakan arsitektur ResNet-50 sebagai base model.

Arsitektur ResNet-50 yang menjadi base model pada penelitian ini dijalankan tanpa adanya konfigurasi khusus sebelum dilanjutkan dengan memodifikasi model dengan menambahkan beberapa layer. Setelah dimodifikasi sesuai dengan model arsitektur yang diusulkan, pendekatan fine-tuning juga dilakukan pada penelitian ini. Tujuan dari modifikasi dan melakukan fine-tuning pada model arsitektur yang diusulkan agar dapat menghasilkan hasil klasifikasi yang optimal.

Untuk merancang arsitektur model yang diusulkan dalam penelitian ini agar menghasilkan hasil klasifikasi yang optimal, diperlukan penentuan parameter yang telah ditentukan jumlah nilai yang digunakan seperti jumlah epoch, batch size, optimizer dan learning rate. Epoch adalah satu siklus pada proses pelatihan model yang berhasil dilewati oleh seluruh dataset [19]. Batch size adalah banyaknya contoh data pelatihan yang digunakan pada setiap epoch [20]. Optimizer adalah salah satu parameter yang digunakan untuk meminimalkan kesalahan sehingga dapat menghasilkan prediksi yang akurat [21] sedangkan learning rate adalah parameter pada proses pelatihan yang digunakan untuk menghitung nilai koreksi bobot pada waktu proses pelatihan dilakukan [22] sehingga learning rate mempunyai peran penting dalam menentukan kinerja model [23]. Setelah jenis parameter telah ditentukan maka selanjutnya dilakukan proses pelatihan arsitektur model yang diusulkan pada penelitian ini. Rincian nilai parameter yang digunakan dalam penelitian dapat dilihat pada Tabel 1.

Tabel 1: Parameter Yang Diuji

Parameter	
Epoch	18
Batch size	16
Optimizer	Adam
Learning Rate	0.0001

Pada Tabel 1 menunjukkan parameter yang diuji pada penelitian ini agar mendapatkan model pelatihan yang terbaik. Model pelatihan tersebut nantinya akan diuji menggunakan data validation sehingga mendapatkan hasil klasifikasi.

## Hasil Klasifikasi

Hasil klasifikasi berupa nilai loss dan nilai accuracy serta hasil prediksi yang didapatkan dari pelatihan arsitektur model yang diusulkan. Nilai loss adalah ukuran seberapa buruk/error dari model yang telah dibuat sedangkan nilai accuracy adalah nilai yang menjadi acuan dalam melihat tingkat keberhasilan model yang telah diusulkan [24]

## Hasil dan Pembahasan

### Pengumpulan Data

Dataset yang digunakan pada penelitian ini didapatkan dari Kaggle [14]. Total dataset yang diperoleh yaitu berjumlah 2751 data citra dengan ekstensi .jpg yang terdiri dari 7 jenis sampah yaitu cardboard (403 data), glass (501 data), metal (410 data), paper (594 data), plastic (482 data), trash (184 data) dan compost (177 data). Setiap kelas dari dataset sampah memiliki contoh yang ditampilkan dalam Gambar 2.



Gambar 2: Contoh Dataset Jenis-Jenis Sampah

### Preprocessing Data

Setelah dilakukan pengumpulan data maka selanjutnya data dibagi menjadi 2 direktori yaitu untuk training dan validation. Direktori training terdiri dari seluruh data citra dengan jumlah total sebanyak 2751 citra dari 7 kelas sedangkan direktori validation berjumlah 777 data citra yang diambil dari setiap kelasnya masing-masing sebanyak 100 citra kecuali kelas “compost” yang tetap diambil 177 citra. Selanjutnya pada dataset training dilakukan preprocessing dengan augmentasi data. Augmentasi data pada penelitian ini menggunakan Image Data Generator. Proses augmentasi citra dilakukan dengan shear\_range, zoom\_range, width\_shift dan height\_shift masing-masing sebesar 0.2 disetiap parameternya. Setelah dilakukan augmentasi data pada dataset training, selanjutnya dataset training dan dataset validation akan dilakukan pembagian data menggunakan teknik Split Validation. Split Validation adalah teknik validasi yang membagi data menjadi dua bagian secara acak [25].

Pada penelitian ini Split Validation menggunakan value 0.1 pada masing-masing direktori artinya data yang digunakan sebesar 10% setiap kelas pada direktori masing-masing. Contoh dari hasil preprocessing ditunjukkan pada Gambar 3 yang di-

tampilkan dengan ukuran 224 x 224 untuk semua gambar.



Gambar 3: Contoh Dataset Hasil Preprocessing

### Proses Klasifikasi

Setelah dilakukan preprocessing selanjutnya akan dilakukan proses klasifikasi dengan base model ResNet-50. Pada penelitian ini, proses klasifikasi diawali dengan load base model ResNet-50 sehingga tidak dilakukan konfigurasi dalam mengatur layer pada model. Setelah itu, model akan dimodifikasi dengan menambahkan beberapa layer beserta jumlah neuron sekaligus fungsi aktivasi sesuai arsitektur model yang diusulkan untuk mengklasifikasi data yang akan dilatih. Model yang akan dilatih menggunakan 512 dan 128 pada hidden layer yang masing-masing diberi fungsi aktivasi ReLu serta diberi dropout 0.2 dan 1 layer untuk output dengan fungsi aktivasi softmax. Fungsi aktivasi softmax digunakan pada proses klasifikasi yang bersifat multiclass [26]. Secara keseluruhan proses dapat disimpulkan seperti pada Tabel 2. Tabel 2 merupakan ringkasan dari arsitektur model yang diusulkan dalam penelitian ini untuk mengklasifikasikan jenis-jenis sampah.

Tabel 2: Ringkasan Arsitektur Model Yang Diusulkan

Layer (type)	Output Shape	Param #
resnet50 (Functional)	(None, 7, 7, 2048)	23587712
global_average_pooling2d_2 (GlobalAveragePooling2D)	(None, 2048)	0
dense_6 (Dense)	(None, 512)	1049088
batch_normalization_4 (BatchNormalization)	(None, 512)	2048
dropout_4 (Dropout)	(None, 512)	0
dense_7 (Dense)	(None, 128)	65664
batch_normalization_5 (BatchNormalization)	(None, 128)	512
dropout_5 (Dropout)	(None, 128)	0
dense_8 (Dense)	(None, 7)	903
Total params: 24,705,927		
Trainable params: 24,651,527		
Non-trainable params: 54,400		

Dalam penelitian ini nilai epoch yang digunakan adalah 18. Epoch digunakan untuk menentukan jumlah iterasi dan dapat mengurangi terjadinya error [27]. Parameter lain seperti batch size, learning rate dan optimizer juga diatur dalam proses ini. Batch size diatur dengan menggunakan nilai sebesar 16, learning rate sebesar 0,0001 dan opti-

mizer menggunakan Adam. Nilai 0,0001 pada learning rate diambil agar tingkat ketelitian model semakin tinggi. Setelah model selesai dilatih menggunakan parameter yang telah ditentukan, pendekatan fine-tuning juga diterapkan pada arsitektur model yang diusulkan. Penerapan fine-tuning pada penelitian ini dilakukan untuk mengubah arsitektur model yang telah diusulkan menjadi trainable dengan menggunakan base\_model.trainable=True. Fine-tuning tersebut dilakukan dengan menggunakan 18 epoch.

### Hasil Klasifikasi

Dalam Berdasarkan hasil pelatihan dari arsitektur model yang diusulkan dengan menggunakan epoch 18 didapatkan rincian seperti pada Tabel 3.

Tabel 3: Hasil Fit Arsitektur Model Yang Diusulkan

no	loss	accuracy	val_loss	val_accuracy
1	1.1001	0.6352	0.4785	0.8312
2	0.5168	0.8284	0.2747	0.8701
3	0.3588	0.8761	0.4237	0.8571
4	0.2755	0.9040	0.2055	0.9610
5	0.2414	0.9219	0.0988	0.9740
6	0.1620	0.9510	0.1003	0.9740
7	0.1647	0.9510	0.1467	0.9610
8	0.1540	0.9538	0.2985	0.9221
9	0.1281	0.9590	0.0508	<b>0.9870</b>
10	0.1215	0.9618	0.0877	<b>0.9870</b>
11	0.1459	0.9562	0.4675	0.9091
12	0.1309	0.9586	0.1022	0.9740
13	0.1124	0.9602	0.0789	0.9740
14	<b>0.1032</b>	0.9665	0.3219	0.8961
15	0.1399	0.9586	<b>0.0731</b>	0.9740
16	0.1060	<b>0.9673</b>	0.1388	0.9481
17	0.1202	0.9610	0.4579	0.8961
18	0.1050	0.9650	0.1596	0.9740


Pada Tabel 3 merupakan hasil pelatihan dengan menggunakan epoch sebanyak 18 kali. Nilai accuracy tertinggi pada data train sebesar 0.9673 pada epoch ke-16 sedangkan nilai loss terendah sebesar 0.1032 yang terjadi pada epoch ke-14. Pada Tabel 3 juga memperlihatkan bahwa accuracy tertinggi pada data validasi dapat mencapai 0.9870 yang terjadi pada epoch ke-9 dan 10 dengan nilai loss terendah mencapai 0.0731 yang terjadi pada epoch ke-15. Setelah proses pelatihan berhasil dilakukan pada arsitektur model yang diusulkan, dalam penelitian ini juga dilakukan fine-tuning menggunakan epoch 18 dengan hasil rincian seperti pada Tabel 4.

Pada Tabel 4 merupakan rincian hasil fit fine-tuning yang dilakukan oleh arsitektur model yang diusulkan dengan menggunakan epoch sebanyak 18 kali. Dapat dilihat bahwa pada data train nilai accuracy tertinggi mencapai 0.9873 yang diperoleh pada epoch ke-18 sedangkan nilai loss terendah mencapai 0.0455 yang diperoleh juga pada epoch ke-18, sedangkan pada data validasi diperoleh nilai accuracy tertinggi mencapai 1 yang diperoleh pada epoch ke-17 dengan nilai loss terendah mencapai 0.0335 yang diperoleh juga pada epoch ke-18.

Tabel 4: Hasil Fit Fine Tuning Arsitektur Model Yang Diusulkan

no	loss	accuracy	val_loss	val_accuracy
1	0.0864	0.9745	0.0739	0.9610
2	0.0515	0.9825	0.0546	0.9740
3	0.0888	0.9741	0.0838	0.9610
4	0.0975	0.9705	0.0629	0.9740
5	0.0840	0.9713	0.1261	0.9610
6	0.0833	0.9693	0.1444	0.9481
7	0.0978	0.9693	0.0346	0.9870
8	0.0888	0.9713	0.1802	0.9481
9	0.0819	0.9725	0.4094	0.9221
10	0.0908	0.9697	0.4539	0.9091
11	0.0886	0.9721	0.2968	0.8831
12	0.0980	0.9677	0.1571	0.9481
13	0.1059	0.9681	0.3032	0.9221
14	0.0602	0.9813	0.4074	0.9091
15	0.0817	0.9809	0.3079	0.9221
16	0.0968	0.9709	0.2731	0.9221
17	0.0738	0.9753	<b>0.0335</b>	<b>1.0000</b>
18	<b>0.0455</b>	<b>0.9873</b>	0.0541	0.9870
accuracy			98.70%	

Dari pelatihan arsitektur model yang diusulkan didapatkan nilai evaluasi kinerja yang dihasilkan dengan nilai akurasi mencapai 98.70%. Visualisasi hasil pelatihan data train dan data validasi dapat dilihat pada Gambar 4.




Gambar 4: Loss training dan validasi selama 36 epoch

Gambar 4 memperlihatkan grafik penurunan loss dari total nilai epoch selama pelatihan sebanyak 36. Grafik menunjukkan bahwa nilai loss pada validation cenderung lebih rendah dibandingkan dengan nilai loss pada training. Namun penurunan pada nilai loss pada validation lebih mengalami fluktuatif daripada nilai loss pada training. Hal ini disebabkan oleh ketidakcocokan antara parameter yang digunakan dan data pelatihan [28].

Begitu pula dengan Gambar 5 yang memperlihatkan grafik kenaikan accuracy pada training dan validation dari total nilai epoch selama pelatihan sebanyak 36. Dapat dilihat bahwa nilai accuracy pada validation telah mampu mencapai 1 sedangkan nilai accuracy pada training tidak. Namun, nilai accuracy pada validasi juga lebih mengalami peningkatan yang fluktuatif dibandingkan dengan nilai accuracy pada training. Dari Gambar 4 dan Gambar 5, didapatkan bahwa nilai loss berbanding terbalik dengan nilai accuracy sehingga apa-

bila semakin tinggi nilai accuracy yang dihasilkan maka nilai loss yang dihasilkan akan semakin rendah. Nilai yang dihasilkan pada accuracy dan loss pada training dan validation juga dipengaruhi oleh banyaknya epoch.



Gambar 5: Accuracy training dan validasi selama 36 epoch



Gambar 6: Visualisasi Hasil Prediksi pada Data Validasi

Jika menggunakan lebih banyak epoch, nilai accuracy pada data training dan validasi akan cenderung meningkat. Berbeda dengan nilai loss, banyaknya jumlah epoch yang digunakan pada proses pelatihan menghasilkan nilai loss semakin kecil. Sehingga dalam meminimalkan nilai loss dapat dilakukan dengan memperbanyak jumlah epoch pada proses pelatihan model. Berdasarkan proses klasifikasi yang telah dilakukan dalam penelitian ini dengan menggunakan parameter-parameter yang telah ditentukan didapatkan hasil klasifikasi seperti pada Gambar 6.

Terdapat contoh hasil prediksi yang dilakukan pada 16 data validasi yang ditunjukkan dalam Gambar 6, dimana untuk label pred artinya kelas prediksi, sedangkan label truth artinya kelas sebe-

narnya. 16 data validasi tersebut merupakan citra dari jenis-jenis sampah yang diambil secara acak. Pada Gambar 6 dapat dilihat sebanyak 16 citra hanya 1 citra yang mengalami kesalahan prediksi sedangkan 15 citra yang lain dapat diprediksi dengan benar, dapat dilihat dari kesamaan hasil antara label pred dan truth.

## Penutup

Dalam penelitian ini, dilakukan klasifikasi citra jenis-jenis sampah yang terbagi menjadi 7 kelas yaitu cardboard, glass, metal, paper, plastic, trash dan compost menggunakan arsitektur ResNet-50 sebagai base model. Penelitian ini memodifikasi base model dengan menambah layer dan melakukan fine-tuning agar arsitektur model yang diusulkan dapat maksimal. Berdasarkan hasil penelitian dapat disimpulkan hasil klasifikasi jenis-jenis sampah menggunakan arsitektur yang diusulkan dengan ResNet-50 menjadi base model didapatkan nilai akurasi sebesar 98,70% dengan rincian parameter batch size = 16, epoch = 18, learning rate = 0.0001 dengan optimizer yaitu Adam. Berdasarkan hasil klasifikasi diharapkan dari penelitian selanjutnya dapat memaksimalkan dengan memodifikasi model arsitektur maupun parameter yang digunakan agar mendapatkan akurasi yang tinggi untuk mengklasifikasikan jenis-jenis sampah.

## Daftar Pustaka

- [1] Q. Maulani dan W. N. Fatimah, "Pengelolaan Sampah Rumah Susun Sederhana Sewa Baleendah, Kecamatan Baleendah Kabupaten Bandung Tahun 2018", *JURNAL KESEHATAN LINGKUNGAN*, vol. 12, no. 2, p. 144, doi: 10.20473/jkl.v12i2.2020.144-153, Apr. 2020.
- [2] A. Z. D. Saputra dan A. S. Fauzi, "Pengolahan Sampah Kertas Menjadi Bahan Baku Industri Kertas Bisa Mengurangi Sampah di Indonesia", *Jurnal Mesin Nusantara*, vol. 5, no. 1, pp. 2775–7390, doi: 10.29407/jmn.v5i1.17522, 2022.
- [3] Anonim, "Capaian Kinerja Pengelolaan Sampah", *SISPN*, diakses daring pada <https://sipsn.menlhk.go.id/sipsn/>, 2022
- [4] M. Tamyiz, L. N. Hamidah, A. Widiyanti dan A. Rahmayanti, "Pelatihan Pengelolaan Sampah Rumah Tangga di Desa Kedungsumur, Kecamatan Krembung, Kabupaten Sidoarjo", *Journal of Science and Social Development*, vol. 1, no. 1, 2018.
- [5] J. Wong, "Aplikasi Klasifikasi Sampah Organik dan Non Organik dengan Metode GLCM Dan LS-SVM", *Bulletin of Computer Science Research*, vol. 3, no. 1, pp. 83–89, doi: 10.47065/bulletincsr.v3i1.198, 2022.
- [6] Leonardo, Yohannes dan E. Hartati, "Klasifikasi Sampah Daur Ulang Menggunakan Support Vector Machine dengan Fitur Local Binary Pattern", *Jurnal Algoritme*, vol. 1, no. 1, pp. 78–90, doi: <https://doi.org/10.35957/algoritme.v1i1.440>, 2020.
- [7] K. M. Sandi, A. P. Yudha, N. D. Aryanto dan M. A. Farabi, "Klasifikasi Sampah Menggunakan Convolutional Neural Network", *Indonesian Journal of Data and Science (IJO-DAS)*, vol. 3, no. 2, pp. 72–81, doi: <https://doi.org/10.56705/ijodas.v3i2.33>, 2022.
- [8] Stephen, Raymond dan H. Santoso, "Aplikasi Convolution Neural Network Untuk Mendeteksi Jenis-Jenis Sampah", *Explore: Jurnal Sistem informasi dan telematika (Telekomunikasi, Multimedia dan Informatika)*, vol. 10, no. 2, pp. 122–130, doi: <http://dx.doi.org/10.36448/jsit.v10i2.1319>, 2019.
- [9] X. Ma, Z. Li and L. Zhang, "An Improved ResNet-50 for Garbage Image Classification", *Tehnicki Vjesnik*, vol. 29, no. 5, pp. 1552–1559, doi: 10.17559/TV-20220420124810, Oct. 2022.
- [10] V. Rao Mangu, K. R. Sekhar, B. Jayanth, and K. Santosh, "An Automatic Garbage Classification System", *JETIR*, vol. 8, no. 6, pp. 4–9, 2021.
- [11] A. Ridhovan dan A. Suharso, "Penerapan Metode Residual Network (ResNet) dalam Klasifikasi Penyakit pada Gandum", *JUPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 7, no. 1, pp. 58–65, doi: <https://doi.org/10.29100/jupi.v7i1.2410>, 2022.
- [12] N. D. Miranda, L. Novamizant dan S. Rizal, "Convolutional Neural Network Pada Klasifikasi Sidik Jari Menggunakan Resnet-50", *Jurnal Teknik Informatika (Jutif)*, vol. 1, no. 2, pp. 61–68, Dec. 2020, doi: 10.20884/1.jutif.2020.1.2.18.
- [13] A. B. Sinuhaji, A. G. Putrada dan H. H. Nuha, "Klasifikasi Gambar dari Prototipe Camera Trap Menggunakan Model ResNet-50 untuk Mendeteksi Satwa Dilindungi", *eProceedings of Engineering*, vol. 8, no. 5, 2021.
- [14] HozPer, "TrashClasification", *Kaggle*, diakses daring pada <https://www.kaggle.com/datasets/haroldobregn/trashclasification>, 2021.
- [15] L. Hakim, H. R. Rahmanto, S. P. Kristanto dan D. Yusuf, "Klasifikasi Citra

- Motif Batik Banyuwangi Menggunakan Convolutional Neural Network”, *Jurnal Teknoinfo*, vol. 17, no. 1, pp. 203–211, doi: <https://doi.org/10.33365/jti.v17i1.2342>, 2023.
- [16] N. Ibrahim et al., “Klasifikasi Tingkat Kematangan Pucuk Daun Teh menggunakan Metode Convolutional Neural Network”, *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 10, no. 1, p. 162, doi: [10.26760/elkomika.v10i1.162](https://doi.org/10.26760/elkomika.v10i1.162), Jan. 2022.
- [17] M. F. N. Syahbani and N. G. Ramadhan, “Klasifikasi Gerakan Yoga dengan Model Convolutional Neural Network Menggunakan Framework Streamlit”, *Jurnal Media Informatika Budidarma*, vol. 7, no. 1, pp. 509–519, doi: [10.30865/mib.v7i1.5520](https://doi.org/10.30865/mib.v7i1.5520), Jan. 2023.
- [18] A. D. Putri, S. Hasanah, M. B. Subkhi, and N. Suciati, “Analisis Penggunaan Praproses pada Metode Transfer Learning untuk Mendeteksi Penyakit Daun Singkong”, *Techno.Com*, vol. 22, no. 2, pp. 336–347, doi: <https://doi.org/10.33633/tc.v22i2.7769>, May 2023.
- [19] S. Yuliany, Aradea dan A. N. Rachman, “Implementasi Deep Learning pada Sistem Klasifikasi Hama Tanaman Padi Menggunakan Metode Convolutional Neural Network (CNN)”, *Jurnal Buana Informatika*, vol. 13, no. 1, pp. 54–65, doi: <https://doi.org/10.24002/jbi.v13i1.5022>, 2022.
- [20] N. Rochmawati, H. H. Badriyah dan Y. Yamasari, “Analisa Learning rate dan Batch size pada Klasifikasi Covid Menggunakan Deep Learning dengan Optimizer Adam”, *Journal Information Engineering and Educational Technology*, vol. 5, no. 2, pp. 44–48, 2021.
- [21] F. Nashrullah, S. A. Wibowo dan G. Budiman, “Investigasi Parameter Epoch Pada Arsitektur ResNet-50 Untuk Klasifikasi Pornografi”, *Journal of Computer, Electronic, and Telecommunication*, vol. 1, no. 1, doi: [10.52435/complete.v1i1.51](https://doi.org/10.52435/complete.v1i1.51), Jul. 2020.
- [22] R. Kurniawan, Y. Mulyani, P. B. Wintoro dan M. Komarudin, “Implementasi Arsitektur Exception pada Model Machine Learning Klasifikasi Sampah Anorganik”, *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 11, no. 2, pp. 233–236, doi: [10.23960/jitet.v11i2.3034](https://doi.org/10.23960/jitet.v11i2.3034), Apr. 2023.
- [23] A. Julianto, A. Sunyoto dan F. W. Wibowo, “Optimasi Hyperparameter Convolutional Neural Network Untuk Klasifikasi Penyakit Tanaman Padi”, *TEKNIMEDIA: Teknologi Informasi dan Multimedia*, vol. 3, no. 2, pp. 98–105, doi: <https://doi.org/10.46764/teknimedia.v3i2.77>, 2022.
- [24] M. Ramadhan, D. I. Mulyana dan M. B. Yel, “Optimasi Algoritma CNN Menggunakan Metode Transfer Learning Untuk Klasifikasi Citra X-Ray Paru-Paru Pneumonia dan Non-Pneumonia”, *Jurnal Teknik Informatika Kaputama (JTIK)*, vol. 6, no. 2, pp. 670–6679, 2022,
- [25] S. L. Jasril, S. Sanjaya, F. Yanto dan M. Affandes, “Klasifikasi Citra Daging Babi dan Daging Sapi Menggunakan Deep Learning Arsitektur ResNet-50 dengan Augmentasi Citra”, *Jurnal Sistem Komputer dan Informatika (JSON)*, vol. 3, no. 4, pp. 450–457, doi: [10.30865/json.v3i4.4167](https://doi.org/10.30865/json.v3i4.4167), Jun. 2022.
- [26] S. Albawi, T. A. Mohammed and S. Al-Zawi, “Understanding of a convolutional neural network”, *International Conference on Engineering and technology (ICET)*, pp. 1–6, 2017,
- [27] W. R. Perdani, R. Magdalena and N. K. C. Pratiwi, “Deep Learning untuk Klasifikasi Glaukoma dengan menggunakan Arsitektur EfficientNet”, *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 10, no. 2, pp. 322–333, doi: [10.26760/elkomika.v10i2.322](https://doi.org/10.26760/elkomika.v10i2.322), Apr. 2022.
- [28] V. Ayumi dan I. Nurhaida, “Klasifikasi Chest X-Ray Images Berdasarkan Kriteria Gejala Covid-19 Menggunakan Convolutional Neural Network”, *JSAI: Journal Scientific and Applied Informatics*, vol. 4, no. 2, pp. 147–153, doi: [10.36085](https://doi.org/10.36085), 2021.

Halaman ini sengaja dikosongkan.