

KLASIFIKASI MEDIA PEMBUANGAN SAMPAH MENGUNAKAN METODE RESNET101-V2

Valentino Ruben Ho^{1*}, Siska Devella², Derry Alamsyah³

^{1,2,3}Informatika, Fakultas Ilmu Komputer dan Rekayasa, Universitas Multi Data Palembang
¹rubenho14@gmail.com, ²siskadevella@mdp.ac.id, ³derry@mdp.ac.id

Kata kunci:

Adam; CNN; deep learning;
Image classification; ResNet

Abstract: Garbage is an object/substance that is no longer used and is left over by humans. One factors that makes waste difficult to decompose is plastic. The use of plastic in human life has become commonplace and is used daily in human activities. Garbage disposal media contributes as an element of environmental pollution. Therefore, researchers conducted research on waste disposal media using the Deep Learning Residual Network (ResNet). ResNet is a type of Convolution Neural Network (CNN) architecture using a pre-trained model. With ResNet there is no need to train data from scratch so it can shorten the time. The data used 15000 images which are divided into Garbage bags, Paper Bags, and Plastic Bags. After testing, an accuracy of 98.65% was obtained with a comparison of training and test data of 80:20 and so it can be concluded that the ResNet method can identify waste disposal media very well.

Abstrak: Sampah adalah benda/zat yang tidak digunakan lagi dan ditinggalkan oleh manusia. Plastik merupakan salah satu faktor yang membuat sampah sulit terurai. Penggunaan plastik dalam kehidupan manusia sudah menjadi hal yang lumrah dan rutin digunakan dalam aktivitas manusia. Media pembuangan limbah juga berkontribusi terhadap pencemaran lingkungan. Oleh karena itu, dalam penelitian ini peneliti meneliti media pengolahan limbah dengan menggunakan metode deep learning residual network (ResNet). ResNet adalah jenis arsitektur convolutional neural network (CNN) yang menggunakan model pra-terlatih. ResNet menghemat waktu karena tidak perlu melatih data dari awal. Data yang digunakan sebanyak 15.000 citra yang terbagi menjadi kantong sampah, kantong kertas, dan kantong plastik. Setelah pengujian, akurasi 98,65% dicapai dengan membandingkan 80% data pelatihan dan 20% pengujian. Dapat disimpulkan bahwa metode ResNet sangat baik dalam mengidentifikasi media pembuangan sampah.

Ho dkk. (2023). Klasifikasi Media Pembuangan Sampah Menggunakan Metode ResNet101-V2. *MDP Student Conference 2023*.

PENDAHULUAN

Sampah merupakan salah satu isu global yang menarik perhatian masyarakat baik global maupun lokal. Hal ini menimbulkan masalah lingkungan, sampah atau biasa disebut limbah merupakan sisa padat dari kegiatan sehari-hari manusia dan/atau proses alam[1]. Limbah sering mengacu pada residu yang tidak diinginkan atau tidak berguna yang ditinggalkan oleh kegiatan dan proses rumah tangga. Bahan-bahan yang tidak diinginkan dalam limbah industri sering disebut sebagai limbah industri. Secara lebih spesifik, sampah dapat dipisahkan berdasarkan sumber, komponen dan jenisnya[2]. Sampah juga dapat menyebabkan peningkatan penyaluran penyakit, serta pencemaran bau di lingkungan dan lain-lain yang mengganggu kenyamanan dan kesehatan lingkungan hidup [3].

Salah satu masalah lingkungan terbesar di dunia yaitu polusi plastik yang mustahil hari ini untuk dihindari dan terus meningkat di seluruh dunia dimana kita tinggal. Hal ini disebabkan banyaknya peralatan zaman sekarang yang menggunakan plastik sebagai bahan pokoknya dikarenakan plastik mudah dibuat dan diolah, tetapi jika kita telusuri akibat dari penggunaan plastik yang berlebihan justru akan merusak lingkungan hidup dimana kita tinggal. Penyebab bertambahnya sampah plastik adalah karena seiring bertambahnya populasi dan produksi plastik sekali pakai yang menumpuk dari waktu ke waktu.

Pada penelitian yang dilakukan untuk mengklasifikasi sampah plastik menggunakan metode *Convolutional Neural Network* (CNN)[4] untuk mengklasifikasikan sampah plastik (anorganik). Metode CNN digunakan karena memiliki akurasi 95% pada penelitian sebelumnya. Pada penelitian yang dilakukan, peneliti menguji setiap model yang didaftarkan selama proses pelatihan dan diperoleh nilai akurasi sebesar 80% untuk pendaftaran model ke-6000 dengan rata-rata nilai *loss* 0,03 dengan pemisahan dataset sebesar 80% : 20% [5].

Pada penelitian yang dilakukan dengan menggunakan arsitektur Resnet50 yang digunakan untuk mengidentifikasi dan melatih 3984 gambar sampah, dan memprediksi 3552 gambar. Hasil penelitian ini mendapatkan hasil akurasi pengenalan sampah sebesar 89,681%, dan akurasi per tiap prediksi sampah sebesar 91,68% dan akurasi citra per kategori sampah sebesar 93,3% [6].

Pada penelitian yang dilakukan oleh untuk Mengklasifikasikan Sel Darah Putih[7] menggunakan arsitektur *ResNet-50*, *GoogleNet*, *VGG-16*, dan *AlexNet*, mendapatkan hasil performa paling tinggi pada bagian akurasi yaitu 94,17% lalu *GoogleNet*, *VGG-16*, dan *AlexNet* masing-masing memiliki akurasi sebesar 93,33%, 91,67% dan 90,00%. Jika perbandingan akurasi ini ditinjau dari selisih akurasi maka *ResNet-50* memiliki akurasi dengan selisih 0,84% terhadap *GoogleNet*, 2,5% terhadap *VGG-16* dan 4,17% terhadap *AlexNet* [8].

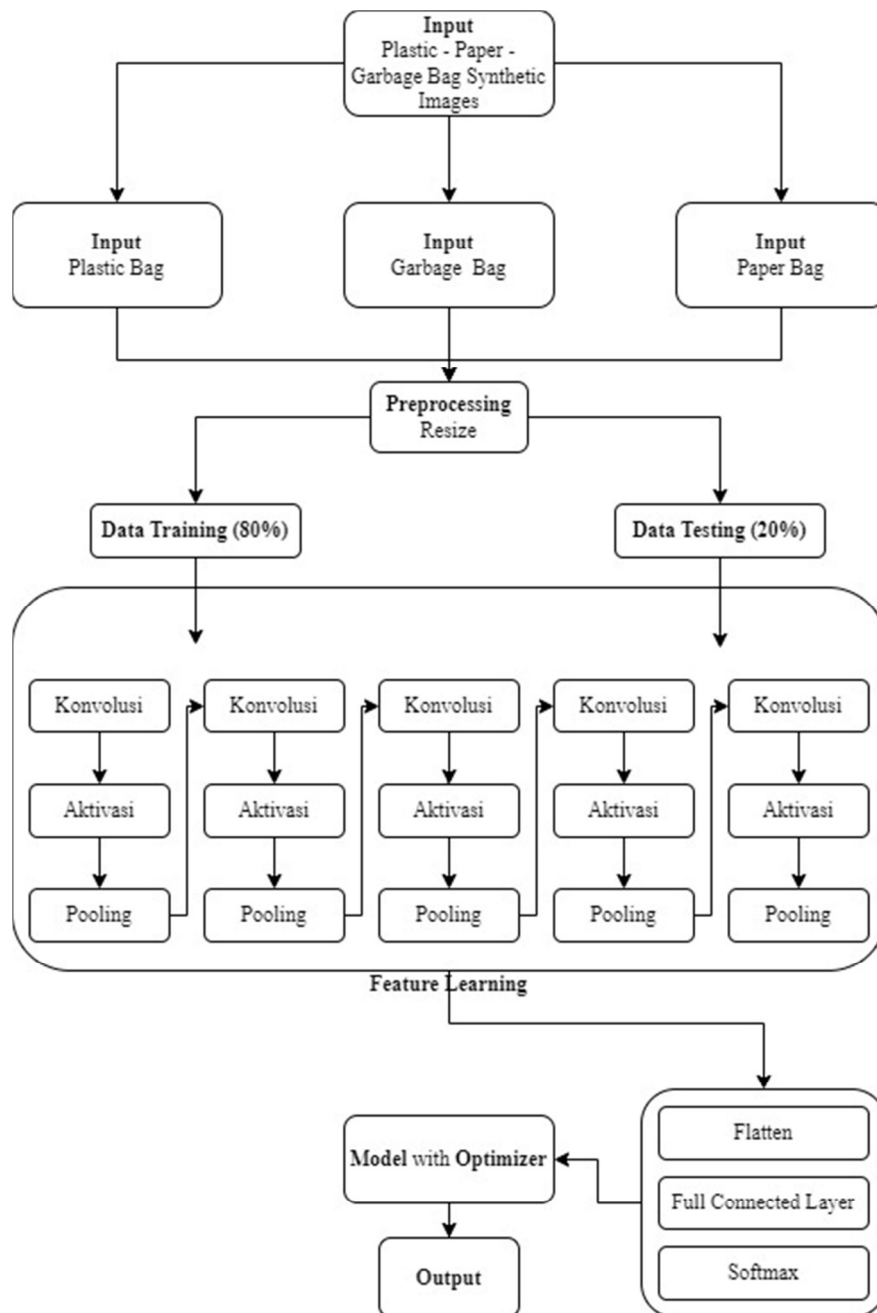
Berlandaskan hasil penelitian terdahulu, maka dapat disimpulkan bahwa metode *Convolutional Neural Network* (CNN) mendapatkan akurasi yang baik untuk melakukan klasifikasi citra. Penelitian ini berfokus untuk menguji tingkat akurasi dari Arsitektur *ResNet-101V2*[9], karena penelitian terdahulu belum ada yang menggunakan arsitektur tersebut untuk mengklasifikasi media pembuangan sampah berdasarkan dataset yang akan dipakai.

METODE

Pada tahapan ini *dataset* kemudian dibagi menjadi 2 bagian, yaitu data training, dan data testing, dengan rasio 80:20 per kategori dari jumlah 15000 data dibagi menjadi 5000 data / kategori. Data untuk training sebesar 80% (4000 data), data untuk testing sebesar 20% (1000 data)[10].

Pada tahapan *preprocessing*, dilakukan *resize* yang berfungsi untuk mengubah ukuran citra yg awalnya 300px x 300px, menjadi 224px x 224px[11], sesuai dengan kebutuhan arsitektur yang akan dipakai, *ResNet-101V2*.

Kemudian masuk ke tahap feature learning yang menggunakan lapisan konvolusi dengan aktivasi ReLU[12], MaxPooling, dan lapisan Fully Connected. Dari hasil lapisan Fully Connected tersebut akan dilakukan perubahan *learning rate optimizer* Adam [13] yang berbeda dan akan masuk ke metode *Resnet-101v2* untuk menghitung hasil prediksi yang akan dijadikan *accuracy*, *precision*, dan *recall*. Metode *Resnet-101v2* tersebut digunakan metode *Skip Connection* [14] yang akan membantu menentukan parameter dan pengulangan yang tepat agar dapat menghasilkan hasil prediksi dari arsitektur tersebut. Skema rancangan sistem dapat dilihat di Gambar 1.



Gambar 1.. Rancangan Sistem

Pada tahapan ini, penulis akan menerapkan CNN dengan arsitektur *ResNet-101V2* terhadap dataset *Plastic Bag*, *Paper Bag*, *Garbage bag synthetic*. Tahapan ini akan diimplementasikan kedalam bahasa pemrograman *Python* menggunakan *Kaggle Notebook*, beberapa parameter yang sudah ada akan di-*tuning* untuk merancang model yang nantinya akan digunakan untuk memberikan tingkat akurasi yang tinggi dalam mengklasifikasi media pembuangan sampah[9]. Skenario pengujian yang dilakukan menggunakan beberapa parameter seperti (1) Data yang akan digunakan adalah citra yang telah dilakukan proses *resize*[11], yang ukuran citra sebelumnya adalah 300px x 300px menjadi 224px x 224px, (2) Arsitektur CNN yang akan

digunakan adalah *ResNet-101V2*. *Optimizer* yang akan digunakan adalah Adam[13]. (3) Di bawah ini merupakan tabel skenario pengujian yang akan dilakukan:

Tabel 1. Skenario Pengujian

Skenario	Learning Rate	Dropout
1	0,001	-
2	0,001	0,02
3	0,0001	-
4	0,0001	0,02

HASIL DAN PEMBAHASAN

Pengujian yang digunakan pada penelitian ini adalah perbandingan *dense layer* ketika diberi *Dropout* sebesar 0,2 dan perubahan *learning rate default* Adam yang bernilai 0,001 menjadi 0,0001. Semua parameter ini akan melalui proses *training* sebanyak 10 *epoch* dan bertujuan untuk menentukan parameter yang bagus dalam klasifikasi media pembuangan sampah.

Sebelum melakukan proses penelitian, gambar akan *dirresize* terlebih dahulu dari 300px x 300px menjadi 224px x 224px, dan untuk pembagian data sebesar 80% data *training* dan 20% data *testing*, tetapi pada proses kali ini digunakan data *validation* sebesar 10% dari total keseluruhan data agar dapat memisahkan dan menentukan hasil *accuracy* dari *dataset* ketika dilatih dengan citra dari *dataset* itu sendiri.

Kemudian hasil dari pelatihan pada *dataset* itu sendiri akan diprediksi dengan 20% dari total keseluruhan *dataset* yang telah dipisahkan pada proses pemrosesan data.

Tabel 2. Pengujian Skenario 1

	Precision	Recall	F1-Score	Support
<i>Garbage Bag Images Resized</i>	0,992901	0,985901	0,989389	993,000
<i>Paper Bag Images Resized</i>	0,988383	0,984571	0,986473	1037,000
<i>Plastic Bag Images Resized</i>	0,974516	0,985567	0,980010	970,000
Accuracy	0,985333	0,985333	0,985333	0,985333
Macro Avg	0,985267	0,985346	0,985291	3000,000
Weighted Avg	0,985395	0,985333	0,985349	3000,000

Hasil dari pengujian *data training* yang menggunakan *optimizer* dengan *learning rate default* sebesar 0,001 dan *dropout dense layer* sebesar 0,2 menghasilkan hasil persentase yang bagus untuk digunakan yaitu 98,5% pada sektor *accuracy* keseluruhan *dataset*, dan persentase keseluruhan *precision* diatas 95% dengan nilai terkecil 97,4% pada label *Plastic Bag Images Resized*, dan *precision* terbesar pada *Garbage Bag Images Resized* dengan persentase 99,2%, lalu pada *F1-Score* terkecil diduduki oleh *Plastic Bag Images Resized* dengan nilai 98% dan nilai terbesar diduduki oleh *Garbage Bag Images Resized* dengan *F1-Score* sebesar 98,9%

Tabel 3. Pengujian Skenario 2

	Precision	Recall	F1-Score	Support
<i>Garbage Bag Images Resized</i>	0,992922	0,988922	0,990918	993,000
<i>Paper Bag Images Resized</i>	0,990347	0,989392	0,989870	1037,000
<i>Plastic Bag Images Resized</i>	0,980513	0,985567	0,983033	970,000
Accuracy	0,988000	0,988000	0,988000	0,988
Macro Avg	0,987927	0,987961	0,987940	3000,000
Weighted Avg	0,988020	0,988000	0,988006	3000,000

Hasil dari pengujian *data training* yang menggunakan *optimizer* dengan *learning rate default* sebesar 0,001 dan tanpa *dropout dense layer* menghasilkan hasil persentase yang bagus untuk digunakan yaitu 98,8% pada sektor *accuracy* keseluruhan *dataset*, dan persentase keseluruhan *precision* diatas 95% dengan nilai terkecil 98% pada label *Plastic Bag Images Resized*, dan *precision* terbesar pada *Garbage Bag Images Resized* dengan persentase 99,2%, lalu pada *F1-Score* terkecil diduduki oleh *Plastic Bag Images Resized* dengan nilai 98,3% dan nilai terbesar diduduki oleh *Garbage Bag Images Resized* dengan *F1-Score* sebesar 99,09%.

Tabel 4. Pengujian Skenario 3

	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
<i>Garbage Bag Images Resized</i>	0,994893	0,980866	0,987830	993,000
<i>Paper Bag Images Resized</i>	0,989392	0,989392	0,989392	1037,000
<i>Plastic Bag Images Resized</i>	0,971545	0,985567	0,978506	970,000
<i>Accuracy</i>	0,985333	0,985333	0,985333	0,985333
<i>Macro Avg</i>	0,985277	0,985275	0,985243	3000,000
<i>Weighted Avg</i>	0,985442	0,985333	0,985355	3000,000

Hasil dari pengujian *data training* yang menggunakan *optimizer Adam* dengan penurunan *learning rate* yang sebelumnya *default* bernilai 0,001 menjadi sebesar 0,0001 dan menggunakan *dropout dense layer* sebesar 0,2 menghasilkan hasil persentase yang bagus untuk digunakan yaitu 98,5% pada sektor *accuracy* keseluruhan *dataset*, dan persentase keseluruhan *precision* diatas 95% dengan nilai terkecil 97,1% pada label *Plastic Bag Images Resized*, dan *precision* terbesar pada *Garbage Bag Images Resized* dengan persentase 99,4%, lalu pada *F1-Score* terkecil diduduki oleh *Plastic Bag Images Resized* dengan nilai 97,8% dan nilai terbesar diduduki oleh *Paper Bag Images Resized* dengan *F1-Score* sebesar 98,9%.

Tabel 5. Pengujian Skenario 4

	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
<i>Garbage Bag Images Resized</i>	0,991927	0,989930	0,990927	993,000
<i>Paper Bag Images Resized</i>	0,989322	0,988428	0,988905	1037,000
<i>Plastic Bag Images Resized</i>	0,981501	0,984536	0,983016	970,000
<i>Accuracy</i>	0,987667	0,987667	0,987667	0,987667
<i>Macro Avg</i>	0,987603	0,987631	0,987616	3000,000
<i>Weighted Avg</i>	0,987676	0,987667	0,987670	3000,000

Hasil dari pengujian *data training* yang menggunakan *optimizer Adam* dengan penurunan *learning rate* yang sebelumnya *default* bernilai 0,001 menjadi sebesar 0,0001 dan tanpa menggunakan *dropout dense layer* menghasilkan hasil persentase yang bagus untuk digunakan yaitu 98,7% pada sektor *accuracy* keseluruhan *dataset*, dan persentase keseluruhan *precision* diatas 95% dengan nilai terkecil 98,1% pada label *Plastic Bag Images Resized*, dan *precision* terbesar pada *Garbage Bag Images Resized* dengan persentase 99,1%, lalu pada *F1-Score* terkecil diduduki oleh *Plastic Bag Images Resized* dengan nilai 98,3% dan nilai terbesar diduduki oleh *Garbage Bag Images Resized* dengan *F1-Score* sebesar 99,09%.

Tabel 6. Akurasi per Skenario

	<i>Skenario 1</i>	<i>Skenario 2</i>	<i>Skenario 3</i>	<i>Skenario 4</i>	<i>Akurasi Rerata</i>
Akurasi	0,985333	0,988000	0,985333	0,987667	0,98658325

SIMPULAN

Kesimpulan dari penelitian ini adalah metode CNN Arsitektur *ResNet101-v2* yang digunakan dapat mengklasifikasi media pembuangan sampah dengan sangat baik, Dari 4 skenario yang sudah dilakukan mendapatkan akurasi rata-rata sebesar 98,65%, Penggunaan *Optimizer Adam* dengan *learning rate default* dan tanpa *Dropout* pada *dense layer* menghasilkan hasil yang lebih baik daripada hasil *tuning* lain, Penggunaan *Optimizer Adam* dengan *learning rate default* dan tanpa *Dropout* pada *dense layer* menghasilkan nilai terbaik dengan akurasi 98,8% F1-score terbesar dengan nilai 99,2% pada *Garbage Bag. Images Resized* dan *F1-Score* dengan total keseluruhan rerata nilai 98,73%.

DAFTAR PUSTAKA

- [1] D. C. Aulia dkk., "Peningkatan Pengetahuan dan Kesadaran Masyarakat Tentang Pengelolaan Sampah Dengan Pesan Jepang," *J. Pengabd. Kesehat. Masy.*, Vol. 1, No. 1, Hal. 62–70, 2021.
- [2] P. N. Dacipta dan R. E. Putra, "Sistem Klasifikasi Limbah Menggunakan Metode Convolutional Neural Network (CNN) pada Webservice Berbasis Framework Flask," *J. Informatics Comput. Sci.*, Vol. 3, No. 04, Hal. 394–402, 2022, doi: 10.26740/jinacs.v3n04.p394-402.
- [3] M. Muhtadi, "Pendampingan Bank Sampah Melati Bersih Berbasis Pemberdayaan Bagi Masyarakat Urban," *J. Pemberdaya. Masy. Media Pemikir. dan Dakwah Pembang.*, Vol. 1, No. 2, Hal. 227, 2017.
- [4] T. Tinaliah, "Penerapan Convolutional Neural Network Untuk Klasifikasi Citra Ekspresi Wajah Manusia pada MMA Facial Expression Dataset," *JATISI (Jurnal Tek. Inform. dan Sist. Informasi)*, Vol. 8, No. 4, Hal. 2051–2059, 2021, doi: 10.35957/jatisi.v8i4.1437.
- [5] T. A. M. Irfan Nugraha Pratama, Tatang Rohana, "Pengenalan Sampah Plastik Dengan Model Convolutional Neural Network," *Conf. Innov. Appl. Sci. Technol. (CIASTECH 2020)*, No. Ciastech, Hal. 691–698, 2020.
- [6] Z. Nie, W. Duan, dan X. Li, "Domestic Garbage Recognition and Detection Based On Faster R-CNN," *J. Phys. Conf. Ser.*, Vol. 1738, No. 1, 2021, doi: 10.1088/1742-6596/1738/1/012089.
- [7] S. Devella, Y. Yohannes, dan C. A. Putra, "Penggunaan Fitur Saliency-SURF Untuk Klasifikasi Citra Sel Darah Putih Dengan Metode SVM," *JATISI (Jurnal Tek. Inform. dan Sist. Informasi)*, vol. 8, no. 4, hal. 1998–2009, 2021, doi: 10.35957/jatisi.v8i4.1547.
- [8] D. M. Wonohadidjojo, "Perbandingan Convolutional Neural Network pada Transfer Learning Method Untuk Mengklasifikasikan Sel Darah Putih," *Ultim. J. Tek. Inform.*, Vol. 13, No. 1, Hal. 51–57, 2021, doi: 10.31937/ti.v13i1.2040.
- [9] H. C. Lee dan A. F. Aqil, "Combination of Transfer Learning Methods for Kidney Glomeruli Image Classification," *Appl. Sci.*, Vol. 12, No. 3, 2022, doi: 10.3390/app12031040.
- [10] S. Aisyah, S. Wahyuningsih, dan F. Amijaya, "Peramalan Jumlah Titik Panas Provinsi Kalimantan Timur Menggunakan Metode Radial Basis Function Neural Network," *Jambura J. Probab. Stat.*, Vol. 2, No. 2, Hal. 64–74, 2021, doi: 10.34312/jjps.v2i2.10292.

- [11] M. Hashemi, “*Enlarging Smaller Images Before Inputting Into Convolutional Neural Network: Zero-Padding Vs. Interpolation*,” *J. Big Data*, Vol. 6, No. 1, 2019, doi: 10.1186/s40537-019-0263-7.
- [12] Ocktavia N. Putri, “*Implementasi Metode CNN Dalam Klasifikasi Gambar Jamur pada Analisis Image Processing (Studi Kasus: Gambar Jamur Dengan Genus Agaricus dan Amanita)*,” Hal. 1–80, 2020, [Daring]. Tersedia pada: [https://dspace.uui.ac.id/bitstream/handle/123456789/23677/16611103Ocktavia Nurima Putri.pdf?sequence=1&isAllowed=y](https://dspace.uui.ac.id/bitstream/handle/123456789/23677/16611103Ocktavia%20Nurima%20Putri.pdf?sequence=1&isAllowed=y)
- [13] N. Attrapadung dkk., “*Adam in Private: Secure and Fast Training of Deep Neural Networks with Adaptive Moment Estimation*,” *Proc. Priv. Enhancing Technol.*, Vol. 2022, No. 4, Hal. 746–767, 2022, doi: 10.56553/popets-2022-0131.
- [14] R. Mar-Cupido, V. García, G. Rivera, dan J. S. Sánchez, “*Deep Transfer Learning For The Recognition of Types of Face Masks As A Core Measure To Prevent The Transmission of COVID-19*,” *Appl. Soft Comput.*, Vol. 125, Hal. 109207, 2022, doi: 10.1016/j.asoc.2022.109207.