



Perbandingan Kinerja Convolutional Neural Network VGG16 dan ResNet34 pada Sistem Klasifikasi Sampah Botol

Performance Comparison of Convolutional Neural Network VGG16 and ResNet34 on Bottled Waste Classification System

William Hutamaputra¹⁾, Rifky Yunus Krisnabayu²⁾, Marrisaeka Mawarni³⁾, Fitra Abdurrachman Bachtiar⁴⁾, Novanto Yudistira⁵⁾

Program Studi Magister Ilmu Komputer, Fakultas Ilmu Komputer, Universitas Brawijaya
Jl. Veteran, Ketawanggede, Kec. Lowokwaru, Malang, Indonesia 65145

Cara sitasi: W. Hutamaputra, R. Y. Krisnabayu, M. Mawarni, F. A. Bachtiar, and N. Yudistira, "Perbandingan Kinerja Convolutional Neural Network VGG16 dan ResNet34 pada Sistem Klasifikasi Sampah Botol," *Jurnal Teknologi dan Sistem Komputer*, vol. 10, no. 2, pp. 136-142, 2022. doi: [10.14710/jtsiskom.2022.14045](https://doi.org/10.14710/jtsiskom.2022.14045) [Online].

Abstract - Plastic bottles are non-organic materials that are difficult to decompose. One solution is to classify and recycle plastic bottle waste. This article compares the performance of CNN (Convolutional Neural Network) based VGG16 and ResNet34 models to identify and classify bottled waste. Each architecture uses 32 batches and uses 10 epochs. The epoch and batch parameters applied to the VGG16 and ResNet34 models will be compared based on accuracy and training time. Based on the test results using the Convolutional Neural Network, the VGG16 architecture has an accuracy of 96.39% and ResNet34 has an accuracy of 91.37% in the classification of plastic bottles and non-plastic bottles.

Keywords – classification; CNN; VGG16; ResNet34

Abstrak – Botol plastik adalah bahan non-organik yang sukar untuk diuraikan. Salah satu solusi yang dapat dilakukan yaitu melakukan klasifikasi dan daur ulang sampah botol plastik. Artikel ini membandingkan kinerja model VGG16 dan ResNet34 berbasis CNN (Convolutional Neural Network) untuk mengidentifikasi dan mengklasifikasikan sampah botol. Masing-masing arsitektur menggunakan ukuran batch yang digunakan pada pengujian adalah 32 batch serta menggunakan 10 epoch. Pada parameter epoch dan batch yang diterapkan pada model VGG16 dan ResNet34 akan dibandingkan berdasarkan akurasi dan waktu pelatihan. Berdasarkan hasil pengujian menggunakan Convolutional Neural Network, arsitektur VGG16 memiliki akurasi sebesar 96,39% dan ResNet34 memiliki akurasi sebesar 91,37% pada klasifikasi botol plastik dan bukan botol plastik.

Kata Kunci – klasifikasi; CNN; VGG16; ResNet34

I. PENDAHULUAN

Plastik merupakan bahan non-organik yang memerlukan waktu 500 hingga 1000 tahun bagi alam untuk menguraikannya [1]. Terdapat berbagai macam produk olahan sekali pakai yang berasal dari bahan plastik yang sering kita temui sehari-hari, contohnya

botol air minum kemasan. Banyaknya produsen yang menggunakan bahan olahan plastik tersebut dikarenakan plastik merupakan bahan yang murah dan mudah dibentuk. Namun dibalik harga yang murah tersebut plastik mengandung zat kimia dan berbahaya seperti Bisphenol A (BPA), thalates, antiminitrooxide, brominated flame retardants dan bahan kimia polifluorinasi yang merupakan faktor risiko serius bagi kesehatan manusia dan kerusakan lingkungan [2].

Jumlah limbah sampah botol yang ditimbun pada TPA dapat diminimalkan dengan melakukan daur ulang. Daur ulang untuk sampah memiliki proses yang berbeda khususnya pada botol plastik, sehingga perlu adanya pemilahan sebelum dilakukan daur ulang. Sampah plastik umumnya diolah menggunakan cara tradisional, yaitu dengan cara membakar plastik pada tempat pembuangan sampah. Cara tradisional tersebut dapat menyebabkan pemborosan sumber daya. Sistem pengelolaan sampah plastik yang buruk juga dapat memberikan dampak negatif bagi lingkungan, baik di tanah, air, maupun udara [3]. Botol plastik di lautan dapat terpapar sinar ultraviolet matahari, yang dapat memicu terjadinya fotodegradasi [4]. Pembuangan plastik sembarangan di tanah menghalangi air meresap ke dalam tanah sehingga kesuburan tanah berkurang dan dapat mengakibatkan banjir serta pembakaran di udara terbuka dapat menyebabkan pelepasan bahan kimia beracun ke udara yang menyebabkan bahaya kesehatan masyarakat [5]. Instrumen tradisional dalam mengklasifikasi sampah plastik memiliki beberapa kekurangan, seperti presisi yang lebih rendah, tenaga, keahlian pengamat dan biaya yang lebih tinggi, ancaman serius bagi kesehatan personel operasi. Hal tersebut bersifat subjektif sesuai dengan keahlian pengamat. Klasifikasi sampah botol tersebut merupakan langkah penting sebelum dilakukan proses pemisahan sampah botol pada sistem pengolahan sampah. Selain itu, pemilahan sampah dengan menggunakan pendeteksi metal akan memerlukan biaya yang mahal. Untuk meminimalkan biaya, dapat diterapkan pengenalan objek dengan menggunakan citra digital.



Dengan berlatar belakang pada masalah tersebut maka diperlukan suatu solusi yang efektif untuk mengatasi kerusakan lingkungan yang disebabkan oleh sampah botol plastik. Salah satunya dengan melakukan klasifikasi dan daur ulang [6]. Cara pertama yaitu pengklasifikasian sampah botol plastik dan sampah botol bukan plastik ke dalam kategori yang ditentukan kemudian didaur ulang agar dapat diolah kembali agar tidak merusak lingkungan. Hal ini dapat diterapkan di kota-kota atau tiap daerah karena hal tersebut merupakan sebuah solusi untuk mengurangi masalah sampah botol plastik [7]. Pada proses klasifikasi diharapkan mampu bekerja secara akurat agar botol plastik dapat didaur ulang [8].

Dalam beberapa dekade terakhir, para peneliti dan ilmuwan telah bekerja untuk mengklasifikasikan gambar secara akurat ke dalam kelas masing-masing. Kokoulin dkk telah membahas klasifikasi botol plastik dan bukan botol plastik dengan membandingkan arsitektur LeNet yang menghasilkan akurasi sebesar 80% dengan arsitektur SqueezeNet yang menghasilkan sebesar 87% [3]. Penelitian yang serupa yang dilakukan menerapkan Convolutional Neural Network model VGG16 untuk memecahkan masalah identifikasi dan klasifikasi sampah [7] [8].

Maka, untuk mengatasi masalah dalam pemilahan sampah botol plastik dan bukan plastik akan dilakukan pengenalan pada komputer. Pada artikel ini peneliti mengusulkan untuk membandingkan kinerja model VGG16 dan ResNet34 berbasis *deep learning* menggunakan CNN (Convolutional Neural Network) dalam mengidentifikasi dan melakukan klasifikasi sampah. Penelitian ini dilakukan dengan menggunakan tingkat akurasi sebagai salah satu penentu tingkat keefektifan model Convolutional Neural Network.

Proses klasifikasi tersebut dapat dilakukan secara efisien dengan bantuan algoritme *machine learning*. Pemanfaatan metode *deep learning* akan membuat hasil model yang lebih baik daripada hanya menggunakan algoritme *machine learning* biasa [9]. Dengan membandingkan arsitektur tersebut, maka pada penelitian berikutnya dapat berfokus pada pengembangan arsitektur daripada melakukan perbandingan untuk pemilihan arsitektur. Penelitian ini diharapkan dapat melakukan klasifikasi sampah botol plastik dan bukan plastik secara akurat. Hal tersebut bertujuan agar sampah botol plastik dapat diolah sehingga tidak menyebabkan pencemaran lingkungan.

Citra sampah botol plastik dan botol bukan plastik adalah subjek data yang akan diklasifikasi. Kumpulan data akan dimasukkan ke dalam model VGG16 *network* dan ResNet34 *network* yang kemudian membandingkan performa pada masing-masing model. Adapun parameter yang kami bandingkan adalah hasil nilai akurasi, presisi, sensitivitas dan F1. Kedua model tersebut menggunakan jaringan dengan ukuran *batch* yang digunakan pada pengujian ini adalah 32 *batch* serta menggunakan 10 *epoch*.

Pada penelitian ini, peneliti juga melakukan perbandingan dengan penelitian sebelumnya. Penelitian

yang telah dilakukan Kokoulin untuk melakukan klasifikasi botol plastik dan bukan botol plastik dengan arsitektur LeNet menghasilkan akurasi sebesar 80% dan arsitektur SqueezeNet sebesar 87% [3]. Penelitian yang telah dilakukan oleh Zhaokun Wang melakukan klasifikasi botol plastik menggunakan metode SVM dengan akurasi yang tinggi sebesar 96% [6]. Penelitian yang serupa yang dilakukan Wang Hao menghasilkan akurasi sebesar 75.6% dengan menggunakan arsitektur VGG16 [8]. Penelitian Wang Hao menggunakan ReLU sebagai fungsi aktivasi dan menambahkan lapisan BN untuk mengembangkan model sehingga menghasilkan akurasi yang lebih tinggi.

Penelitian sebelumnya yang dilakukan oleh Hulyalkar [7] menerapkan Convolutional Neural Network model VGG16 untuk memecahkan masalah identifikasi dan klasifikasi sampah domestik. Penerapan *deep learning* sebagai pengenalan dan klasifikasi gambar menghasilkan akurasi sebesar 75,6% sehingga akurasi masih perlu ditingkatkan dan dilakukan perbandingan dengan model network lainnya untuk mengetahui model yang ideal untuk menyelesaikannya. Penelitian untuk mendeteksi botol plastik dilakukan juga oleh Jinwang Wang dengan metode Fast R-CNN dengan akurasi sebesar 86.4% [10].

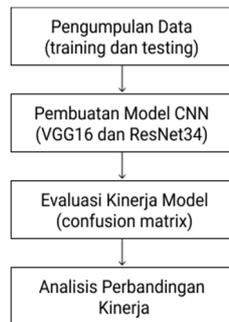
Tachwali [9] mengusulkan sistem klasifikasi botol plastik dengan kecerdasan buatan (AI). sistem mengklasifikasikan botol berdasarkan komposisi kimia dan warnanya dicoba. Pengukuran reflektansi Near Infrared (NIR) digunakan untuk mengidentifikasi kelas komposisi botol. Kamera Charged Couple Device (CCD) dengan perpaduan analisis diskriminan kuadrat (QDA) dan tree classifiers digunakan untuk mendeteksi warna botol. penelitian ini mengklasifikasikan botol berdasarkan komposisi kimia dan warnanya. Hal ini menghasilkan akurasi klasifikasi warna 92% untuk botol bening sementara 96% dicapai untuk botol buram. Akurasi klasifikasi agregat dari sistem gabungan (yaitu klasifikasi akurat warna serta komposisi kimia) adalah 83,48%.

Penelitian yang telah dilakukan oleh Victor Atlilha, peneliti melakukan perbandingan arsitektur VGG19 dan ResNet101 untuk melakukan *encoder* terhadap keterangan gambar. Hasil penelitian tersebut menyatakan bahwa arsitektur ResNet101 menghasilkan performa yang lebih baik daripada VGG19 [11].

Pemilihan metode CNN dilakukan dengan metode Convolutional Neural Network yang menggabungkan ekstraksi fitur dan pengenalan gambar dalam proses pengenalan gambar secara tradisional serta menggunakan gambar asli sebagai data masukan [3]. Hal tersebut dapat menghindari proses pemrosesan gambar yang kompleks dari metode pengenalan tradisional, dan dapat mengekstrak fitur paling penting dari data yang tidak dapat diekstrak secara manual dari sekumpulan sampel data yang terbatas, sehingga hasil pengenalan *deep learning* lebih dapat diandalkan, dan kemampuannya dalam mengenali gambar juga lebih kuat [8].

II. METODE PENELITIAN

Bagian ini menjelaskan mengenai tahapan yang dilakukan selama penelitian. Proses diawali dengan pengumpulan dan *preprocessing data*, kemudian dilanjutkan dengan membangun model CNN dengan arsitektur VGG16 dan ResNet34. Tahap terakhir adalah peneliti melakukan perbandingan hasil performa dari masing-masing model yang sudah dibangun. Gambar 1. menggambarkan detail tahapan yang dilakukan selama penelitian.



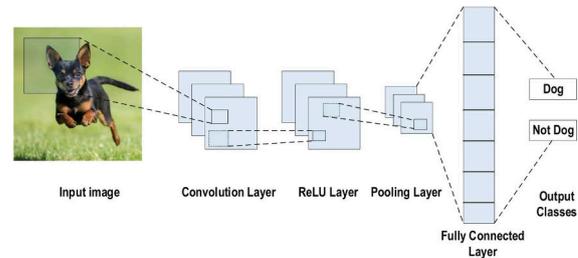
Gambar 1. Metode Penelitian

A. Pengumpulan Data

Penelitian ini akan melakukan sebuah proses klasifikasi gambar. Fokus utama dalam klasifikasi gambar adalah untuk pengembangan tempat sampah pintar (*smart bins*) yang berguna untuk membedakan antara botol plastik dan botol bukan plastik seperti botol minuman dengan bahan kaca. Data didapatkan dari 2 sumber yaitu https://github.com/nish10/Image-Classifer-using-TensorFlow/blob/master/data/train/alcohol_beverage_bottles/.com.google.Chrome.0779PS dan <https://www.kaggle.com/moezabid/bottles-and-cans>. Total himpunan data (*dataset*) yang digunakan adalah berjumlah 4449. Himpunan data untuk data latih berjumlah 2794 dengan pembagian 1361 untuk botol plastik dan 1433 untuk botol bukan plastik. Data uji yang digunakan berjumlah 1655 dengan pembagian 833 untuk gambar botol plastik dan 822 untuk gambar botol bukan plastik. Peneliti menggunakan 10% (0.1) dari keseluruhan data latih untuk melakukan validasi saat pelatihan sehingga proporsi data latih yang digunakan dalam pelatihan adalah 90% (0.9) dari keseluruhan data latih yang didapat.

B. Convolutional Neural Network (CNN)

Convolutional Neural Network atau CNN adalah jenis algoritme jaringan saraf dengan struktur jaringan yang kompleks yang dapat digunakan untuk memproses apa pun mulai dari gambar hingga audio. Arsitektur dalam CNN juga terinspirasi dari neuron dalam otak manusia atau hewan [12]. CNN merupakan algoritma yang paling populer dan dapat diterapkan untuk melakukan klasifikasi pada gambar dimana akan menerima masukkan berupa gambar dan melakukan ekstraksi fitur (*feature learning*) secara otomatis.

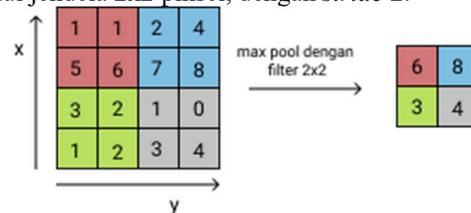


Gambar 2. Arsitektur CNN [10]

Dalam CNN terdapat dua bagian inti yakni *feature extraction layer* dan *fully-connected layer*. Arsitektur CNN terdiri atas beberapa layer konvolusi yang berjenjang dan saling terhubung, rentetan konvolusi tersebut diakhiri oleh layer klasifikasi yang terletak pada *fully connected layer* [8].

C. VGG16

Pada arsitektur VGG16, menggunakan data *input* berupa RGB dengan ukuran 224x224 piksel. VGG mengubah arsitektur dari AlexNet dengan mengganti filter ukuran 11x11 dan 5x5 menjadi 3x3. Dalam konfigurasi VGG16 juga memiliki filter 1x1 untuk transformasi linear. VGG dapat menghasilkan model yang lebih akurat terutama untuk kasus mengidentifikasi dan klasifikasi gambar [8]. Pada VGG16 terdapat 2 jenis *pooling* yaitu *Max Pooling* dan *Average Pooling*. *Max Pooling* adalah proses *pooling* dengan mengembalikan nilai yang tertinggi dari nilai yang dilewati oleh kernel. *Average Pooling* adalah proses *pooling* dengan mengembalikan nilai dengan menghitung rata-rata dari nilai yang dilewati oleh *kernel* [13]. *Pooling* dilakukan melalui jendela 2x2 piksel, dengan *stride* 2.



Gambar 3. Max-pooling dengan filter 2x2

Langkah selanjutnya yakni masuk pada lapisan konvolusi dimana terdapat tiga *Fully-Connected* layer. Dua lapisan pertama masing-masing memiliki 4096 saluran. Pada lapisan ketiga melakukan klasifikasi ILSVRC 1000 arah dan berisi 1.000 saluran untuk masing-masing kelas. Lapisan terakhir adalah lapisan *soft-max*. Konfigurasi dari lapisan yang terhubung sepenuhnya sama di semua jaringan [14].

Pada jaringan VGG16 memiliki kekurangan yaitu parameter model dan kompleksitas perhitungan selama pelatihan sangat tinggi. Hal tersebut mengakibatkan waktu pelatihan yang cukup lama. Untuk mengatasinya, maka penggunaan *Sigmoid* dan *Tanh* dengan *Rectified Linear Units* (ReLU) (Persamaan 1) [8]. Fungsi *Sigmoid* dan *Tanh* digunakan untuk pelatihan fungsi aktivasi. Dengan membandingkan fungsi aktivasi yang tidak linear, keluaran tidak dapat menyajikan data dengan gradasi tertentu. Selain menggunakan fungsi *batchnormalized* (BN) juga dapat meningkatkan

performa. BN ditambahkan setelah *fully connected layer*[15]. BN akan mencegah terjadinya *overfitting*[16] pada proses pelatihan seperti proses *dropout* [17].

$$ReLU(x) = \max(0, x) \quad (1)$$

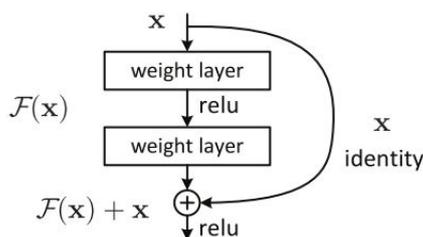
D. ResNet34

Dalam ResNet34, arsitektur ini bekerja dengan cara melewati beberapa lapisan konvolusi dengan tujuan proses pelatihan menjadi lebih efektif [18], [19]. Identitas *shortcut* dapat langsung digunakan jika ukuran dimensi antara masukan dan keluaran sama. Ketika dimensi pada lapisan bertambah, maka terdapat 2 skenario yang terjadi. Skenario pertama adalah *shortcut* melakukan pemetaan identitas dengan *extra zero entries padded*. Skenario kedua adalah *shortcut* untuk mencocokkan dimensi dengan konvolusi 1x1 [20]. Pada ResNet34 yang memiliki 34 layer yang dikelompokkan pada 18 lapisan besar. ResNet dengan 34 lapisan menunjukkan arsitektur yang dapat digeneralisasikan dari masukan [21].

Masalah yang diselesaikan dengan adanya ResNet adalah *vanishing gradient*. *Vanishing Gradient* merupakan sebuah kondisi dimana meningkatnya kedalaman / *depth* sebuah *network* akan terdapat suatu titik dimana akurasi mengalami titik jenuh dan turun dengan cepat. Salah satu solusi yang diambil yakni dengan melewati beberapa layer. Hal ini terjadi dalam ResNet yakni disebut dengan *shortcut* atau *skip connection*. Dalam penelitian mendefinisikan *building block* yang dinyatakan pada persamaan 2.

$$y = F(x, \{W_i\}) + x \quad (2)$$

dimana x adalah masukan vektor, sedangkan y adalah keluaran vektor dari sebuah layer. Fungsi $F(x, \{W_i\})$ mendefinisikan residual *mapping*. Pada Gambar 4 dapat digunakan untuk memperjelasnya fungsi residual.



Gambar 4. Residual learning: a building block [14]

E. Membangun Model CNN

Langkah selanjutnya adalah fokus pada pengembangan model menggunakan CNN. Penelitian ini menggunakan Python sebagai bahasa pemrograman. Dalam membangun CNN, akan memanfaatkan arsitektur yakni VGG16 dan ResNet34. Keduanya umum digunakan dalam *deep convolutional neural networks* [11]. Dalam membangun model CNN dilakukan proses *pretrained* yang artinya memanfaatkan model yang sudah dibangun sebelumnya.

F. Evaluasi Performa Model

Setelah sebuah model selesai dibangun, maka akan dilakukan perbandingan performa yang kedua model yang sudah dibangun. Model pertama dibangun menggunakan arsitektur VGG16, sedangkan model kedua dibangun dengan arsitektur ResNet34. Perbandingan evaluasi menggunakan matriks akurasi dan *epoch* [14] serta ditambahkan waktu pelatihan. Akurasi akan menggambarkan proporsi dari data yang benar diprediksi oleh model baik *true positive* (TP) atau *true negative* (TN) dibandingkan dengan total jumlah data. Selain menggunakan akurasi, penelitian ini menambahkan perhitungan lain seperti *recall*, *precision*, dan *f1-score*. Hal ini diperlukan untuk memperjelas performa model karena akurasi tidak bisa menjadi satu-satunya dasar pengukuran performa. Ketiganya adalah perhitungan performa yang umum digunakan dalam penelitian. [22]. *Precision* menggambarkan seberapa sering model berhasil memprediksi data berlabel benar. Sedangkan *recall* yakni seberapa banyak jumlah data positif yang berhasil yang diprediksi dengan positif. Sedangkan *f1-score* merupakan rata-rata harmonik antara *precision* dan *recall*. Dengan mengetahui nilai-nilai tersebut, peneliti dapat membandingkan performa arsitektur VGG16 dan ResNet34. Pada penelitian ini, peneliti menambahkan kurva *receiver operating characteristic* (ROC) yang juga dapat digunakan untuk membandingkan performa antar model [23]. Dalam sebuah kurva ROC terdapat dua sumbu yakni sumbu horizontal yang menggambarkan proporsi dari *false positives rate* (FPR) dan sumbu vertikal yang menggambarkan proporsi dari *true positives rate* (TPR).

$$accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (3)$$

$$recall = \frac{TP}{TP+FN} \quad (4)$$

$$precision = \frac{TP}{TP+FP} \quad (5)$$

$$f1 - score = \frac{2*(precision*recall)}{(precision+recall)} \quad (6)$$

G. Penarikan Kesimpulan

Pada tahap terakhir yakni ditarik sebuah kesimpulan tentang perbedaan metode yang digunakan dalam CNN yakni VGG16 dan ResNet34. Pertimbangan yang diangkat adalah memuat bagaimana performa kedua *encoder* CNN tersebut dalam studi klasifikasi sampah botol plastik dan botol bukan plastik. Selain kesimpulan akan juga diberikan saran khususnya untuk penelitian berikutnya.

III. HASIL DAN PEMBAHASAN

Menurut hasil proses pengujian yang telah dilakukan dan dideskripsikan pada jurnal ini, sampah botol adalah subjek data yang akan diklasifikasi. Kumpulan set akan



dimasukkan ke dalam model VGG16 *network* dan ResNet34 *network*. Ukuran *batch* yang digunakan pada pengujian adalah 64. Pada kedua jenis model *network* menggunakan 10 *epoch*. Dengan parameter *epoch* dan *batch* yang dilakukan oleh model VGG16 dan ResNet34, peneliti akan membandingkan model VGG16 dan ResNet34 berdasarkan ketepatan dalam klasifikasi dan waktu pelatihan masing-masing *epoch* pada arsitektur CNN.

Tabel 1. Hasil Matriks konfusi pada ResNet34

	Botol Plastik	Bukan Botol Plastik
Botol Plastik	747	86
Bukan Botol Plastik	57	765

Tabel 2. Hasil Matriks konfusi pada VGG16

	Botol Plastik	Bukan Botol Plastik
Botol Plastik	777	56
Bukan Botol Plastik	4	818

Tabel 3. Hasil akurasi, presisi, sensitivitas, dan F1 score pada arsitektur ResNet34 dan VGG16

Resnet34	
<i>Accuracy</i>	91.36%
<i>Sensitivity (Recall)</i>	89.68%
<i>Precision</i>	92.91%
<i>F1 score</i>	91.26%
VGG16	
<i>Accuracy</i>	96.37%
<i>Sensitivity (Recall)</i>	93.28%
<i>Precision</i>	99.49%
<i>F1 score</i>	96.28%

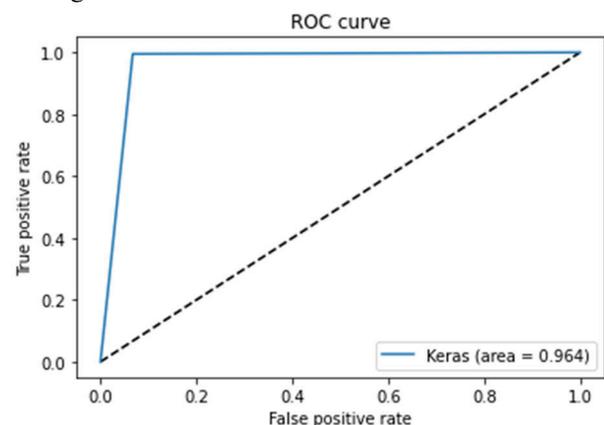
Setiap pelatihan yang dilakukan oleh arsitektur dapat terjadi *overfitting* dan *underfitting*. *Overfitting* adalah keadaan dimana data yang digunakan dalam pelatihan adalah data terbaik. *Underfitting* adalah keadaan dimana data yang dibuat tidak mewakili dengan data sebenarnya sehingga hasil prediksi pada arsitektur sangat kurang baik. Indikasi besarnya *overfitting* adalah selisih yang besar antara akurasi data latih dengan akurasi data validasi [24]. Pada ResNet34, akurasi *epoch* ke-10 pada pelatihan dan validasi adalah 94,1% dan 91,15%. Pada *epoch* pertama hingga *epoch* ke-10 terdapat penurunan selisih akurasi antara pelatihan dan validasi. Pada VGG16, akurasi *epoch* ke-10 pada pelatihan dan validasi adalah 98.48% dan 98.75%. Pada *epoch* pertama hingga *epoch* ke-10 terdapat penurunan selisih akurasi antara pelatihan dan validasi sehingga dapat dikatakan *overfitting* semakin berkurang pada arsitektur ini. Indikasi besarnya *underfitting* terjadi jika nilai akurasi

dalam pelatihan relatif rendah. Akurasi pelatihan ResNet34 dan VGG16 cukup tinggi sehingga arsitektur dapat melakukan prediksi dengan cukup benar.

Tabel 4. Waktu Pelatihan pada ResNet34 dan VGG16

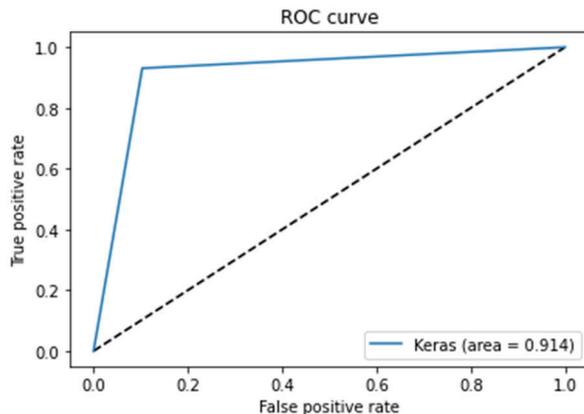
Epoch ke	Waktu Pelatihan (detik) [ResNet34]	Waktu Pelatihan (detik) [VGG16]
1	191	107
2	127	106
3	125	108
4	122	109
5	123	107
6	123	106
7	119	106
8	118	106
9	119	106
10	118	106
Total	1285	1067

Setelah melakukan testing, pengujian akan menghasilkan nilai akurasi dari kedua jenis model. Penjelasan hasil pengujian berada pada tabel 1 dan tabel 2. Model VGG16 memiliki nilai *True Positif Rate* (TPR) sebesar 93,28% dan nilai *False Positif Rate* (FPR) sebesar 0,49%. Model ResNet34 memiliki nilai TPR sebesar 89,68% dan nilai FPR sebesar 6.93%. Pada model VGG16 memiliki akurasi sebesar 96,39%. Pada model ResNet34 memiliki akurasi sebesar 91,37%. Hasil kurva ROC pada arsitektur VGG16 dan ResNet34 ditunjukkan pada gambar 5 dan gambar 6. Tabel 3 menunjukkan hasil akurasi, presisi, sensitivitas, dan F1 score pada arsitektur ResNet34 dan VGG16. Pada tabel 4 menunjukkan waktu pelatihan yang ditempuh pada setiap *epoch* pada masing-masing arsitektur.



Gambar 1. Kurva ROC pada arsitektur VGG16

Pada model VGG16 memiliki waktu pelatihan yang lebih cepat dibandingkan ResNet34. Berdasarkan penelitian sebelumnya yang dilakukan oleh Muhammed Talo, model VGG16 menghasilkan akurasi yang lebih baik dibandingkan dengan ResNet34 [25]. Penelitian tersebut dinyatakan dalam tabel 5. Pernyataan tersebut juga didukung dengan penelitian yang dilakukan oleh Shanchen Pang [26].



Gambar 2. Kurva ROC pada arsitektur ResNet34

Berdasarkan tingkat akurasi dan waktu pelatihan, VGG16 adalah model yang baik daripada ResNet34 untuk menyelesaikan permasalahan karena memiliki akurasi yang tinggi dan waktu pelatihan yang relatif cepat. Hal tersebut terjadi karena pada arsitektur VGG16 tidak memiliki tahap lapisan residu pada model seperti ResNet34 sehingga tidak ada data pembelajaran yang terkompres. Dalam hal ini VGG16 memiliki performa yang lebih tinggi dengan jumlah data yang relatif untuk pembelajaran [27]. VGG16 juga memiliki banyak parameter sehingga membuat arsitektur tersebut dapat mengingat banyak pola dari setiap bagian [28].

IV. KESIMPULAN

Berdasarkan hasil pengujian Convolutional Neural Network, arsitektur VGG16 dan ResNet34 memiliki akurasi sebesar 96,39% dan 91,57% pada pengenalan botol plastik dan bukan botol plastik, sehingga VGG16 adalah arsitektur CNN yang lebih baik dibandingkan dengan ResNet34 dari segi akurasi dan waktu pelatihan.

Saran untuk penelitian selanjutnya adalah melakukan modifikasi dari arsitektur jaringan Convolutional Neural Network. Dengan memodifikasi arsitektur, maka arsitektur bisa memiliki tingkat akurasi yang lebih tinggi dibandingkan dengan arsitektur asal. Modifikasi arsitektur dapat dilakukan dengan menambahkan atau mengurangi lapisan dengan parameter tertentu.

DAFTAR PUSTAKA

[1] S. A. Ghadage and M. N. A. Doshi, "IoT based garbage management (Monitor and acknowledgment) system: A review," *Proceedings of the International Conference on Intelligent Sustainable Systems, ICISS 2017*, no. Iciss, pp. 642–644, 2018, doi: 10.1109/ISS1.2017.8389250.

[2] R. Proshad, T. Kormoker, M. S. Islam, M. A. Haque, M. M. Rahman, and M. M. R. Mithu, "Toxic effects of plastic on human health and environment: A consequences of health risk assessment in Bangladesh," *International Journal of Health*, 2017, doi: 10.14419/ijh.v6i1.8655.

[3] A. N. Kokoulin, A. I. Tur, and A. A. Yuzhakov, "Convolutional neural networks application in

plastic waste recognition and sorting," *Proceedings of the 2018 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering, ElConRus 2018*, vol. 2018-Janua, pp. 1094–1098, 2018, doi: 10.1109/ElConRus.2018.8317281.

[4] S. Budiman, D. Suryasaputra, and D. Ristianti, "Fotodegradasi Zat Warna Tekstil dengan Fotokatalis TiO₂, Al₂O₃ dan H₂O₂," *Conference Prosiding*, no. April, 2014.

[5] A. Okunola A, O. Kehinde I, A. Oluwaseun, and A. Olufiropo E, "Public and Environmental Health Effects of Plastic Wastes Disposal: A Review," *Journal of Toxicology and Risk Assessment*, 2019, doi: 10.23937/2572-4061.1510021.

[6] Z. Wang, B. Peng, Y. Huang, and G. Sun, "Classification for plastic bottles recycling based on image recognition," *Waste Management*, 2019, doi: 10.1016/j.wasman.2019.03.032.

[7] K. S. Hulyalkar S., Deshpande R., Makode K., "Implementation of Smartbin Using Convolutional Neural Networks," *International Research Journal of Engineering and Technology*, vol. 5, no. 4, pp. 3352–3358, 2018.

[8] H. Wang, "Garbage recognition and classification system based on convolutional neural network vgg16," *Proceedings - 2020 3rd International Conference on Advanced Electronic Materials, Computers and Software Engineering, AEMCSE 2020*, pp. 252–255, 2020, doi: 10.1109/AEMCSE50948.2020.00061.

[9] Y. Tachwali, Y. Al-Assaf, and A. R. Al-Ali, "Automatic multistage classification system for plastic bottles recycling," *Resources, Conservation and Recycling*, 2007, doi: 10.1016/j.resconrec.2007.03.008.

[10] J. Wang, W. Guo, T. Pan, H. Yu, L. Duan, and W. Yang, "Bottle Detection in the Wild Using Low-Altitude Unmanned Aerial Vehicles," *2018 21st International Conference on Information Fusion, FUSION 2018*, vol. 2, pp. 439–444, 2018, doi: 10.23919/ICIF.2018.8455565.

[11] V. Atliha and D. Sesok, "Comparison of VGG and ResNet used as Encoders for Image Captioning," *2020 IEEE Open Conference of Electrical, Electronic and Information Sciences, eStream 2020 - Proceedings*, pp. 0–3, 2020, doi: 10.1109/eStream50540.2020.9108880.

[12] L. Alzubaidi *et al.*, "Review of deep learning: concepts, CNN architectures, challenges, applications, future directions," *J Big Data*, vol. 8, p. 53, 2021, doi: 10.1186/s40537-021-00444-8.

[13] D. M. S. Arsa and A. A. N. H. Susila, "VGG16 in Batik Classification based on Random Forest," *Proceedings of 2019 International Conference on Information Management and Technology, ICIMTech 2019*, no. August, pp. 295–299, 2019, doi: 10.1109/ICIMTech.2019.8843844.

[14] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image



- recognition,” *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*, pp. 1–14, 2015.
- [15] T. Ogawa, H. Lu, A. Watanabe, I. Omura, and T. Kamiya, “Identification of normal and abnormal from ultrasound images of power devices using VGG16,” *International Conference on Control, Automation and Systems*, vol. 2020-Octob, no. Iccas, pp. 415–418, 2020, doi: 10.23919/ICCAS50221.2020.9268275.
- [16] H. Li, J. Li, X. Guan, B. Liang, Y. Lai, and X. Luo, “Research on Overfitting of Deep Learning,” *Proceedings - 2019 15th International Conference on Computational Intelligence and Security, CIS 2019*, pp. 78–81, 2019, doi: 10.1109/CIS.2019.00025.
- [17] K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition,” *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, vol. 2016-Decem, pp. 770–778, 2016, doi: 10.1109/CVPR.2016.90.
- [18] K. Zhang, M. Sun, T. X. Han, X. Yuan, L. Guo, and T. Liu, “Residual Networks of Residual Networks: Multilevel Residual Networks,” *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 28, no. 6, pp. 1303–1314, 2018, doi: 10.1109/TCSVT.2017.2654543.
- [19] S. H. Lee, S. Hosseini, H. J. Kwon, J. Moon, H. Il Koo, and N. I. Cho, “Age and gender estimation using deep residual learning network,” *2018 International Workshop on Advanced Image Technology, IWAIT 2018*, pp. 1–3, 2018, doi: 10.1109/IWAIT.2018.8369763.
- [20] A. Demir, F. Yilmaz, and O. Kose, “Early detection of skin cancer using deep learning architectures: Resnet-101 and inception-v3,” *TIPTEKNO 2019 - Tip Teknolojileri Kongresi*, vol. 2019-Janua, pp. 2019–2022, 2019, doi: 10.1109/TIPTEKNO47231.2019.8972045.
- [21] A. Mahajan and S. Chaudhary, “Categorical Image Classification Based on Representational Deep Network (RESNET),” *Proceedings of the 3rd International Conference on Electronics and Communication and Aerospace Technology, ICECA 2019*, pp. 327–330, 2019, doi: 10.1109/ICECA.2019.8822133.
- [22] R. P. S. Putri and I. Waspada, “Penerapan Algoritma C4.5 pada Aplikasi Prediksi Kelulusan Mahasiswa Prodi Informatika,” *Khazanah Informatika: Jurnal Ilmu Komputer dan Informatika*, vol. 4, no. 1, p. 1, 2018, doi: 10.23917/khif.v4i1.5975.
- [23] C. Vercellis, *Business Intelligence: Data Mining and Optimization for Decision Making*. 2009.
- [24] A. Ghasemian, H. Hosseinmardi, and A. Clauset, “Evaluating overfit and underfit in models of network community structure,” *IEEE Transactions on Knowledge and Data Engineering*, vol. 32, no. 9, pp. 1722–1735, 2020, doi: 10.1109/TKDE.2019.2911585.
- [25] M. Talo, O. Yildirim, U. B. Baloglu, G. Aydin, and U. R. Acharya, “Convolutional neural networks for multi-class brain disease detection using MRI images,” *Computerized Medical Imaging and Graphics*, vol. 78, no. October, 2019, doi: 10.1016/j.compmedimag.2019.101673.
- [26] S. Pang *et al.*, “VGG16-T: A novel deep convolutional neural network with boosting to identify pathological type of lung cancer in early stage by ct images,” *International Journal of Computational Intelligence Systems*, vol. 13, no. 1, pp. 771–780, 2020, doi: 10.2991/ijcis.d.200608.001.
- [27] E. Kim, N. Panchi, and G. S. Dahiya, “Towards automated identification of ice features for surface vessels using deep learning,” *Journal of Physics: Conference Series*, vol. 1357, no. 1, 2019, doi: 10.1088/1742-6596/1357/1/012042.
- [28] D. I. Swasono, H. Tjandrasa, and C. Fathicah, “Classification of tobacco leaf pests using VGG16 transfer learning,” *Proceedings of 2019 International Conference on Information and Communication Technology and Systems, ICTS 2019*, pp. 176–181, 2019, doi: 10.1109/ICTS.2019.8850946.