

Deep-RIC: Plastic Waste Classification using Deep Learning and Resin Identification Codes (RIC)

Deep-RIC: Algoritma Klasifikasi Sampah Plastik Otomatis berbasis Deep Learning dan Resin Identification Codes (RIC)

**Latifah Listyalina¹, Yudianingsih², Ajie Wibowo Soedjono³, Evrita Lusiana Utari⁴,
Dhimas Arief Dharmawan^{5*}**

¹ Program Studi Teknologi Pengolahan Karet dan Plastik, Politeknik Negeri ATK Yogyakarta, Indonesia

^{2,4} Program Studi Teknik Elektro, Universitas Respati Yogyakarta, Indonesia

³ Program Studi Sistem Informasi, Universitas Respati Yogyakarta, Indonesia

⁵ Program Studi Informatika, Universitas Pembangunan Nasional Veteran Yogyakarta, Indonesia

¹latifah.listyalina@atk.ac.id, ²yudiabiheppi@gmail.com, ³ajiesisfor@respati.ac.id,

⁴evrita_lusiana@yahoo.com, ^{5*}dhimas.arief@upnyk.ac.id

*: *Penulis korespondensi (corresponding author)*

Article's Information / Informasi Artikel

Received: May 2022

Revised: May 2022

Accepted: June 2022

Published: June 2022

Abstract

Purpose: In this study, the authors designed an algorithm based on deep learning that can automatically classify plastic waste according to Resin Identification Codes (RIC). Design/methodology/approach: The proposed algorithm is built through several stages as follows. In the first stage, image acquisition of plastic waste is carried out, which is the input of the designed algorithm. The acquired plastic waste image must display the resin code of the plastic waste to be classified. Furthermore, the acquired image is divided into two sets, namely training and testing sets. The training set contains images of plastic waste used in the training phase of the deep learning architecture DenseNet-121 to identify the resin code of each plastic waste image and classify it into the appropriate class. The training phase is run for 100 epochs, and at each epoch, the cross-entropy loss function is calculated, which expresses the performance of the deep learning architectures in classifying plastic waste images.

Findings/result: In the next stage, a trained deep learning architecture is used to classify the plastic waste images from the test set. Classification performance in the test set is also expressed as the cross-entropy loss function value. In

Keywords: deep learning; image; plastic waste classification; Resin Identification Codes

Kata kunci: citra; deep learning; klasifikasi sampah plastik, Resin Identification Codes

addition, the accuracy value has also been calculated, which shows the percentage of the number of plastic waste images successfully classified correctly to the total number of plastic waste images in the test set, which the best accuracy is equal to 85%.

Originality/value/state of the art: Given the high accuracy achieved by our algorithm, this work can be used as a reference by other researchers, specifically to benchmark their plastic wastes classification methods developed in the future.

Abstrak

Tujuan: Pada penelitian ini, penulis merancang sebuah algoritma berbasis deep learning yang mampu melakukan klasifikasi sampah plastik secara otomatis sesuai dengan *Resin Identification Codes (RIC)*.

Perancangan/metode/pendekatan: Algoritma yang diusulkan dibangun melalui beberapa tahap sebagai berikut. Pada tahap pertama, dilakukan akuisisi citra sampah plastik yang menjadi masukan dari algoritma yang dirancang. Citra sampah plastik hasil akuisisi harus menampilkan kode resin dari sampah plastik yang akan diklasifikasikan. Selanjutnya, citra hasil akuisisi dibagi menjadi dua set, yaitu set pelatihan dan pengujian. Set pelatihan berisikan citra sampah plastik yang digunakan pada tahap pelatihan arsitektur deep learning DenseNet-121 agar mampu mengidentifikasi kode resin dari setiap citra sampah plastik dan mengklasifikasikannya ke dalam kelas yang sesuai. Tahap pelatihan dijalankan selama 100 epoch, dan pada setiap epoch, dihitung nilai fungsi rugi cross entropy yang menyatakan performa dari arsitektur DenseNet-121 dalam mengklasifikasikan citra sampah plastik.

Hasil: Pada tahap selanjutnya, arsitektur deep learning terlatih digunakan untuk mengklasifikasikan citra sampah plastik yang berasal dari set pengujian. Performa klasifikasi pada set pengujian juga dinyatakan dalam bentuk nilai fungsi rugi cross entropy. Selain itu, telah dihitung pula nilai akurasi yang menunjukkan persentase jumlah citra sampah plastik yang berhasil diklasifikasikan dengan benar terhadap jumlah seluruh citra sampah plastik pada set pengujian, yaitu akurasi terbaik sebesar 85%.

Keaslian/state of the art: Dengan akurasi tinggi yang diperoleh, penelitian ini dapat digunakan oleh peneliti di bidang klasifikasi sampah plastik sebagai referensi, dan tolok ukur performa algoritma klasifikasi sampah plastik di masa mendatang.

1. Pendahuluan

Plastik merupakan salah satu bahan baku utama kemasan berbagai produk, mulai dari produk makanan, minuman, kesehatan, kecantikan, dan masih banyak lainnya. Banyaknya kemudahan yang ditawarkan oleh plastik seperti murah, ringan, kuat, dan tahan air menjadikannya material kemasan yang paling diminati [1]. Pada tahun 2021, Badan Pusat Statistik (BPS) melaporkan rata-rata limbah plastik di Indonesia dalam beberapa tahun terakhir mencapai 66 juta ton per tahun. Angka ini jelas menggambarkan bahwa plastik tidak bisa dilepaskan dari kehidupan masyarakat, khususnya di Indonesia.

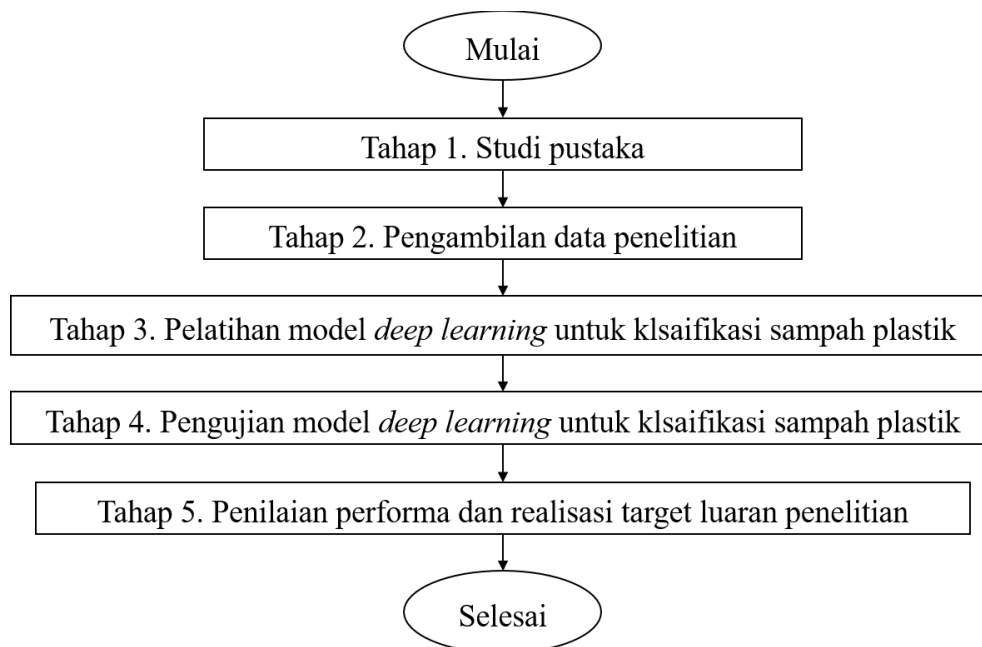
Di balik berbagai kemudahan yang ditawarkan, plastik rupanya menyimpan bahaya besar bagi kelestarian lingkungan dan ekosistem. Seperti yang disebutkan oleh [2], plastik pada umumnya tidak dapat terurai dengan mudah dan cepat, dan konsep kemasan plastik sekali pakai semakin menambah dampak buruk plastik tidak hanya terhadap lingkungan, biota, dan ekosistem, namun juga lambat laun mulai mengganggu kesehatan manusia dan ekonomi. Hal senada juga disampaikan oleh [3], yang menyebutkan bahwa seiring berjalannya waktu, dampak buruk yang ditimbulkan oleh sampah plastik menjadi semakin serius, dan kebijakan pembatasan plastik telah menjadi pembahasan hangat secara global. Menariknya, pandemi COVID-19 yang diklaim dapat memperbaiki kualitas udara di bumi melalui kebijakan pengurangan mobilitas yang berimbas pada penurunan jumlah penggunaan kendaraan bermotor setiap harinya, ternyata di lain sisi justru turut menyumbang polutan plastik. Seperti yang dilaporkan oleh [4], pemeriksaan COVID-19 menggunakan RT-PCR menyumbang lebih dari 10 juta ton sampah plastik per Agustus 2020.

Sebagai respons dari menumpuknya limbah plastik di berbagai belahan dunia, upaya pengolahan sampah plastik mulai dilakukan secara intensif. Salah satu konsep pengolahan plastik yang umum di masyarakat dikenal dengan istilah 3R, yakni “Reduce, Reuse, Recycle”. Tujuan utama dari konsep ini adalah untuk membangun kesadaran masyarakat akan pentingnya penggunaan material yang berkelanjutan dengan memaksimalkan efisiensi sumber daya dan material [5]. Meskipun tampak sederhana, realisasi konsep 3R bukan merupakan hal yang mudah sebab memerlukan berbagai proses dan tahapan sebelum material dari sampah plastik tersebut dapat digunakan kembali, khususnya apabila hendak dijadikan produk dengan wujud yang berbeda dari produk semula. Salah satu tahapan yang dibutuhkan pada proses pengolahan sampah plastik adalah pemilahan dan klasifikasi sampah plastik sesuai jenis material yang digunakan. Salah satu mekanisme yang dapat dilakukan adalah dengan mengacu ke Resin Identification Codes (RIC). Proses pemilahan tentu dapat dilakukan secara manual oleh manusia, dengan cara melihat kode resin yang tertera pada sampah plastik, maupun secara otomatis, dimana identifikasi kode resin dilakukan dengan bantuan komputer. Identifikasi secara manual tentu akan menjadi rumit, melelahkan, dan memakan waktu yang apabila dilakukan pada sampah plastik dalam jumlah yang besar.

Berdasarkan permasalahan yang telah dipaparkan, tim penulis dapat dirancang sebuah algoritma komputer yang mampu mengidentifikasi kode resin secara otomatis dan selanjutnya mengklasifikasikan sampah plastik sesuai jenis material penyusunnya. Demi mendapatkan hasil klasifikasi yang akurat, algoritma klasifikasi akan dirancang berbasis deep learning yang telah terbukti memiliki performa yang sangat baik pada sejumlah tugas klasifikasi citra.

2. Metode

Penelitian ini berjenis kuantitatif dan menggunakan data sekunder, yakni data citra sampah plastic yang diunduh dari <https://www.kaggle.com/datasets/piaoya/plastic-recycling-Codes>. Citra akan diklasifikasikan ke jenis-jenis sampah plastik sesuai dengan kode resin yang tertera dengan bantuan model *deep learning*. Pengukuran yang dilakukan berupa pengukuran tingkat akurasi model *deep learning* yang dirancang dalam mengklasifikasikan citra sampah plastik ke jenis-jenis sampah plastik yang sesuai. Adapun tahapan dalam penelitian ini diilustrasikan pada Gambar 1 di bawah dan diuraikan sebagai berikut.



Gambar 1. Tahapan Penelitian.

2.1. Studi Pustaka

Studi pustaka dilakukan dengan mencari informasi dari buku dan penelitian-penelitian terlebih dahulu untuk meningkatkan penelitian sebelumnya. Selain itu, studi pustaka dimaksudkan untuk mengetahui teknologi terkini terkait *deep learning*. Berikut adalah beberapa informasi pendukung jalannya penelitian ini.

2.1.1. Penelitian Terkait

Beberapa upaya telah dilakukan untuk merancang algoritma komputer guna klasifikasi sampah plastik secara otomatis. Upaya klasifikasi sampah plastik otomatis telah dilakukan oleh [1]. Pada penelitian tersebut, foto-foto botol plastik diambil dan beberapa langkah pra-pemrosesan seperti segmentasi area plastik botol dari latar belakang, deteksi tepi, penghilangan noise, penghilangan lubang, peningkatan citra, dan segmentasi citra. Efek warna botol serta label (merk) dihilangkan menggunakan operasi ini. Hanya tiga jenis plastik yang digunakan karena rasio keberadaannya lebih tinggi daripada jenis plastik lainnya di dunia. Proses klasifikasi dilakukan pada fitur-fitur hasil ekstraksi lima metode ekstraksi yang berbeda, yaitu sebagai Principal Component Analysis (PCA), Kernel PCA (KPCA), Fisher's Linear Discriminant Analysis (FLDA), Singular Value

Decomposition (SVD) dan Laplacian Eigenmaps (LEMAP). Selanjutnya, Support Vector Machine (SVM) dipilih untuk menjalankan tugas klasifikasi dan teknik pemungutan suara mayoritas digunakan sebagai mekanisme keputusan. Secara otomatis, algoritma ini dapat mengklasifikasikan jenis botol plastik dengan akurasi pengenalan sekitar 90%.

Pemanfaatan model pembelajaran mesin untuk klasifikasi sampah juga dilakukan oleh [6]. Disebutkan pada penelitian tersebut, biasanya, botol dengan warna berbeda memiliki nilai daur ulang yang berbeda, sehingga klasifikasi daur ulang botol plastik berdasarkan pengenalan citra adalah cara yang efektif. Untuk mengklasifikasikan botol plastik pada ban berjalan, hubungan posisi antar botol terlebih dahulu didefinisikan sebagai tiga kategori, yaitu terputus-putus, berdekatan dan tumpang tindih. Yang terputus-putus dapat dengan mudah diidentifikasi dengan rasio daerah cekung dan cembung berdasarkan gambar mereka. Untuk botol yang berdekatan dan tumpang tindih, metode kombinasi yang disebut transformasi jarak dan segmentasi ambang diusulkan untuk membedakan hubungan posisinya. Setelah botol yang berdekatan diidentifikasi, metode pencarian titik cekung berdasarkan lambung cembung akan digunakan untuk memisahkan botol daur ulang yang berdekatan lebih lanjut. Kemudian, warna botol lepas dan botol yang berdekatan diidentifikasi karena terlalu rumit dan sulit untuk mengenali warna dan memisahkan botol yang tumpang tindih. Pada aspek pengenalan warna, warna botol daur ulang dibagi menjadi tujuh kategori dalam proses penyortiran. Fitur warna di bagian bawah digunakan untuk mewakili salah satu botol daur ulang karena mungkin ada tutup botol dan label masing-masing di bagian atas dan tengah botol, yang mengakibatkan pengenalan yang salah. Algoritma ReliefF diterapkan untuk memilih fitur warna dari botol daur ulang dan warna diidentifikasi oleh algoritma support vector machine (SVM) dan hasil eksperimen menunjukkan bahwa akurasi pengenalan warna botol daur ulang mencapai 94,7%.

Sedikit berbeda dengan dua penelitian sebelumnya, penelitian yang dilakukan oleh [7] menerapkan pembelajaran mesin tanpa pengawasan pada data hiperspektral inframerah gelombang pendek untuk membangun model klasifikasi plastik. Model yang dirancang berhasil membedakan antara dua belas plastik (PE, PP, PET, PS, PVC, PVDF, POM, PEEK, ABS, PMMA, PC, dan PA12) dan kegunaannya dibuktikan lebih lanjut dengan mengenali tiga sampel yang tidak diketahui (PS, PMMA, PC). Hasilnya, pencitraan hiperspektral dengan panjang gelombang dari 955 hingga 1700 nm pada tiga belas plastik berbeda yang dianalisis oleh PCA telah menunjukkan bahwa rentang spektral cukup untuk membedakan plastik.


Berkembangnya teknologi *deep learning* turut dimanfaatkan oleh beberapa peneliti untuk merancang model klasifikasi sampah plastik otomatis, salah satunya penelitian yang dilakukan oleh [5]. Penelitian tersebut menggunakan teknik pemrosesan citra, dan kecerdasan buatan, khususnya teknik *deep learning* untuk memisahkan sampah plastik ke dalam tujuh kategori yaitu, HDPE, LDPE, PVC, PS, PP, PE-HD, dan PET. Teknik yang diusulkan diklaim sebagai teknik yang tidak memerlukan sumber daya yang besar dan dapat beroperasi pada perangkat portabel. Model *deep learning* juga dimanfaatkan oleh [8] untuk mengklasifikasikan berbagai jenis bahan plastik yang biasa ditemukan di aliran limbah plastik campuran (MPW). Tepatnya, convolutional neural network (CNN) diterapkan pada representasi sudut Gram dari spektrum eksperimental ATR-FTIR (attenuated total refleksi-Fourier transform infrared spectroscopy) untuk mengklasifikasikan sepuluh jenis plastik yang berbeda. Dari hasil eksperimen tampak bahwa representasi matriks 2 dimensi (2D) ini menunjukkan korelasi antara frekuensi yang berbeda (bilangan gelombang) dan mengarah pada peningkatan yang signifikan dalam akurasi

klasifikasi, dibandingkan dengan penggunaan langsung spektrum (representasi vektor 1D), dengan akurasi klasifikasi keseluruhan lebih dari 87%.

2.1.2. Plastik dan Resin Identification Codes (RIC)

Plastik adalah bahan penting yang digunakan dalam berbagai aplikasi seperti pengemasan makanan, konstruksi, transportasi, perawatan kesehatan, dan elektronik. Sejak tahun 1856 (ketika seluloid plastik pertama kali ditemukan), industri plastik berkembang pesat tidak hanya dalam hal volume, tetapi juga dalam hal variasi bahan yang dihasilkan. Ekspansi yang cepat ini telah menghasilkan jejak lingkungan yang besar; Sebagai gambaran, pada tahun 2015, hampir 381 juta ton sampah plastik campuran (MPW) dihasilkan, ini lebih banyak dari total berat manusia di bumi (316 juta ton). Khususnya, hanya 20% dari semua plastik yang diproduksi yang didaur ulang [9]; tingkat daur ulang ini sangat rendah dibandingkan dengan bahan lain (misalnya, aluminium memiliki tingkat daur ulang hampir 100%). Sebagian besar PU berakhir di tempat pembuangan sampah dan insinerator; tempat pembuangan sampah tidak berkelanjutan, terutama ketika ketersediaan lahan dibatasi [10]. Insinerasi MPW mengurangi kebutuhan akan tempat pembuangan akhir, tetapi proses ini dapat melepaskan zat berbahaya ke atmosfer [11].

Karena ada sekitar 50 jenis plastik dengan ratusan jenis yang berbeda, American Society of Plastics Industry mengembangkan kode penandaan standar untuk membantu konsumen mengidentifikasi dan menyortir jenis utama plastik; sehingga klasifikasi selama klasifikasi dapat dilakukan dengan mudah. Produk plastik tersebut diberi label dan dipisahkan menjadi tujuh kelompok yaitu Polyethylene Terephthalate (PETE), High Density Polyethylene (HDPE), Low Density Polyethylene (LDPE), Vinyl/Polyvinyl Chloride (PVC), Polypropylene (PP), Polystyrene (PS), dan OTHER (Jenis lain dari produk plastik). Mekanisme pelabelan ini selanjutnya disebut sebagai Resin Identification Codes (RIC) sebagaimana ditunjukkan pada Gambar 2.



Gambar 2. Skema Klasifikasi Plastik berdasarkan Resin Identification Codes (RIC).

2.1.3. Densely Connected Neural Network

Deep neural networks (DNN), sebagai salah satu algoritma deep learning telah menetapkan tolok ukur dalam banyak tugas pemrosesan citra yang mencakup klasifikasi citra [12][13][14], pengenalan objek [14][15], dan segmentasi citra [17][18][19]. Performa seperti itu terutama karena digunakannya beberapa lapisan tersembunyi di DNN untuk menangkap fitur-fitur penting. Oleh karena itu, banyak peneliti mencoba mengembangkan arsitektur yang lebih dalam untuk meningkatkan kinerja mereka dalam tugas-tugas di atas.

Meskipun kita mungkin mendapat manfaat dari menggunakan banyak lapisan di DNN, membangun DNN yang memiliki performa tinggi itu tidaklah mudah, misalnya, kita tidak bisa hanya sekadar menyematkan lapisan dengan jumlah besar ke jaringan, tanpa memikirkan tugas dan efek yang ditimbulkan oleh masing-masing lapisan tersebut. Seperti yang telah disoroti oleh beberapa karya sebelumnya, menanamkan banyak lapisan untuk membangun jaringan saraf yang lebih dalam tanpa mekanisme khusus dapat menyebabkan masalah hilangnya gradien (*vanishing gradient problem*). Pertambahan jumlah layer mau tidak mau akan membuat jalur transmisi untuk informasi dan gradien semakin panjang. Akibatnya, fitur dari sisi lapisan input atau gradien dari sisi yang berlawanan bisa hilang sebelum mencapai tujuan.

Baru-baru ini, Densely Connected Convolutional Networks (DenseNets) [20] dan Residual Neural Networks (ResNets) [21] adalah dua jaringan populer untuk mengatasi masalah gradien yang hilang. Jaringan ini menggunakan konfigurasi konektivitas tertentu untuk memastikan sirkulasi informasi dan gradien. Lewati koneksi di ResNets memungkinkan aliran data melewati beberapa lapisan sehingga tidak hilang sebelum mencapai sisi yang diinginkan. Di sisi lain, DenseNets menerapkan pola konektivitas padat untuk melakukan tugas yang sama, memungkinkan setiap lapisan yang terlibat untuk terhubung ke semua lapisan berikutnya. Oleh karena itu, lapisan ke- l di DenseNets dapat memiliki masukan dalam bentuk aliran data dari semua lapisan sebelumnya. Sebagai contoh, apabila kita misalkan informasi pada lapisan ke- l sebagai x_l , maka x_l akan tersusun sebagai kombinasi dari informasi pada lapisan-lapisan sebelumnya, misal x_0, x_1, \dots, x_{l-1} :

$$x_l = D_l([x_0, x_1, \dots, x_{l-1}]), \quad (1)$$

di mana $D_l(\cdot)$ mengacu pada fungsi gabungan operasi, misalnya seperti fungsi aktivasi.

2.2. Pengambilan Data Penelitian

Pengambilan data dilakukan dengan mengunduh citra sampah plastic dari <https://www.kaggle.com/datasets/piaoya/plastic-recycling-Codes>. Ukuran setiap citra pada dataset tersebut berukuran 200×200 piksel dengan format JPG. Masing-masing citra dilengkapi dengan label jenis sampah plastic yang sesuai dengan kode resin yang tertera pada citra tersebut. Label ini diperlukan untuk melatih model *deep learning* agar mampu mengenali kode-kode resin dan untuk mengukur performa model pada tahap pengujian. Rincian data penelitian disajikan pada Tabel 1.

Tabel 1. Rincian Data Penelitian

Kelas	Jenis Plastik	Jumlah Citra
0	Polyethylene Terephthalate (Pet)	121
1	High-Density Polyethylene (HDPE)	76
2	Polyvinyl Chloride (PVC)	24
3	Low-Density Polyethylene (LDPE)	90
4	Polypropylene (PP)	192
5	Polystyrene (PS)	39
6	Other Plastics	64
7	No Plastics	79

Selanjutnya, citra hasil akuisisi akan dibagi menjadi dua set, yaitu set pelatihan dan pengujian. Set pelatihan berisikan citra sampah plastik yang digunakan pada tahap pelatihan arsitektur DNN DenseNet-121 agar mampu mengidentifikasi kode resin dari setiap citra sampah plastik dan mengklasifikasikannya ke dalam kelas yang sesuai. Adapun set pengujian berisikan citra sampah plastik yang digunakan pada untuk menguji arsitektur DNN DenseNet-121 terlatih. Proses pembagian dilakukan dengan metode *stratified random sampling* dengan rasio data pelatihan dan pengujian 9:1, 8:2, 7:3, dan 6:4.

2.3. Pelatihan Model *Deep Learning* untuk Klasifikasi Sampah

Sebagaimana telah dijelaskan sebelumnya, penelitian ini menggunakan beberapa arsitektur DNN untuk mengklasifikasikan sampah plastik ke kelas yang sesuai. Tahap pelatihan akan dijalankan dalam sejumlah epoch, dan pada setiap epoch, akan dihitung nilai fungsi rugi *cross entropy* yang menyatakan performa dari arsitektur *deep learning* dalam mengklasifikasikan citra sampah plastik. Tahap pelatihan dijalankan sesuai dengan parameter pada Tabel 2.

Tabel 2. Parameter pelatihan arsitektur DNN

Parameter	Nilai
Ukuran citra	224×224 piksel
Epoch	100
Batchsize	32
Learning rate	10 ⁻⁴
Optimizer	Adam
Loss function	Cross Entropy
Arsitektur	DenseNet-121

2.4. Pengujian Model *Deep Learning* untuk Klasifikasi Sampah

Pada tahap ini, arsitektur DNN terlatih digunakan untuk mengklasifikasikan citra sampah plastik yang berasal dari set pengujian. Performa klasifikasi pada set pengujian juga dinyatakan dalam bentuk nilai fungsi rugi *cross entropy*. Selain itu, dihitung pula nilai akurasi dan F-1 *score* yang menunjukkan persentase jumlah citra sampah plastik yang berhasil diklasifikasikan dengan benar terhadap jumlah seluruh citra sampah plastik pada set pengujian dan perbandingan jumlah citra sampah plastik yang berhasil diklasifikasikan dengan benar terhadap jumlah prediksi positif. Akurasi dan F1-*score* dapat dihitung sesuai persamaan berikut:

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN}, \quad (2)$$


$$F1 - score = \frac{2 \times TP}{2 \times TP + FP + FN} \quad (3)$$

dengan TP, TN, FP, dan FN menunjukkan *true positive*, *true negative*, *false positive*, dan *false negative*.

3. Hasil dan Pembahasan

3.1. Rasio Data Pelatihan dan Pengujian 9:1


Gambar 3 menunjukkan *confusion matrix* hasil percobaan menggunakan rasio data pelatihan dan pengujian 9:1. Dari data yang ditampilkan oleh *confusion matrix* tersebut, model DenseNet-121 telah berhasil mengklasifikasikan citra sampah plastik dengan akurasi 85,51% dan F-1 score 80,05%. Dari hasil yang diperoleh, dapat disimpulkan bahwa model mampu mengatasi masalah *imbalanced class*, terbukti dengan kecilnya selisih nilai antara Akurasi dan F-1 score. Hal ini dikarenakan model telah mendapatkan data pelatihan yang cukup dan telah mencakup seluruh distribusi data pengujian.



Gambar 3. *Confusion Matrix* Hasil Percobaan menggunakan Rasio Data Pelatihan dan Pengujian 9:1.

3.2. Rasio Data Pelatihan dan Pengujian 8:2


Gambar 4 menunjukkan *confusion matrix* yang memuat hasil pengujian pada percobaan menggunakan rasio data pelatihan dan pengujian 8:2. Dari data yang ditampilkan oleh *confusion matrix* tersebut, model DenseNet-121 telah berhasil mengklasifikasikan citra sampah plastik dengan akurasi 83,94% dan F-1 score 79,08%. Dari hasil yang diperoleh, dapat disimpulkan bahwa model cukup baik dalam mengatasi masalah *imbalanced class*, terbukti dengan kecilnya selisih nilai antara Akurasi dan F-1 score. Hal ini dikarenakan model telah mendapatkan data pelatihan yang cukup dan telah mencakup seluruh distribusi data pengujian.



Gambar 4. *Confusion Matrix* Hasil Percobaan menggunakan Rasio Data Pelatihan dan Pengujian 8:2.

3.3. Rasio Data Pelatihan dan Pengujian 7:3


Gambar 5 menunjukkan *confusion matrix* yang memuat hasil pengujian pada percobaan menggunakan rasio data pelatihan dan pengujian 7:3. Dari data yang ditampilkan oleh *confusion matrix* tersebut, model DenseNet-121 telah berhasil mengklasifikasikan citra sampah plastik dengan akurasi 77,18% dan F-1 score 69,97%. Dari hasil yang diperoleh, dapat disimpulkan bahwa model memiliki performa yang sedang. Hal ini dimungkinkan karena data pelatihan hanya mencakup sebagian besar distribusi data pelatihan, sehingga tidak cukup untuk membuat generalisasi pada data pengujian.



Gambar 5. *Confusion Matrix* Hasil Percobaan menggunakan Rasio Data Pelatihan dan Pengujian 7:3.

3.4. Rasio Data Pelatihan dan Pengujian 6:4

Gambar 6 menunjukkan *confusion matrix* yang memuat hasil pengujian pada percobaan menggunakan rasio data pelatihan dan pengujian 6:4. Dari data yang ditampilkan oleh *confusion matrix* tersebut, model DenseNet-121 telah berhasil mengklasifikasikan citra sampah plastik dengan akurasi 76,64% dan F-1 score 68,53%. Dari hasil yang diperoleh, dapat disimpulkan bahwa model memiliki performa yang sedang. Hal ini dimungkinkan karena data pelatihan hanya mencakup sebagian besar distribusi data pelatihan, sehingga tidak cukup untuk membuat generalisasi pada data pengujian.



Gambar 6. *Confusion Matrix* Hasil Percobaan menggunakan Rasio Data Pelatihan dan Pengujian 6:4.

3.5. Rekapitulasi Hasil Percobaan

Hasil empat percobaan yang telah dilakukan menarik untuk dianalisis lebih lanjut. Analisis dalam hal ini mencakup observasi efek yang ditimbulkan oleh variasi rasio data pelatihan dan pengujian serta penentuan rasio data pelatihan dan pengujian yang menghasilkan performa model terbaik. Tabel 3 menunjukkan rekapitulasi dari hasil empat percobaan yang telah dilaksanakan. Menurut Tabel 3, terdapat kecenderungan bahwa model DenseNet-121 memiliki performa yang kurang memuaskan ketika jumlah data pelatihan tidak mencukupi, seperti pada rasio 6:4, dan 7:3. Dalam hal ini, rasio 9:1 memberikan performa terbaik, dibandingkan dengan rasio yang lain.

Tabel 3. Rekapitulasi Hasil Percobaan

Data Pelatihan : Data Pengujian	Akurasi (%)	F-1 Score (%)
9:1	85,51	80,05
8:2	83,94	79,08
7:3	77,18	69,97
6:4	76,64	68,53

4. Kesimpulan dan Saran

Pada penelitian ini, penulis telah merancang sebuah algoritma berbasis deep learning yang mampu melakukan klasifikasi sampah plastik secara otomatis sesuai dengan *Resin Identification Codes (RIC)*. Algoritma yang diusulkan telah dibangun melalui beberapa tahap seperti akuisisi citra sampah plastik, pelatihan arsitektur deep learning DenseNet-121, pengujian arsitektur deep learning terlatih untuk mengklasifikasikan citra sampah plastik yang berasal dari set pengujian, dan penilaian performa dinyatakan dalam bentuk nilai fungsi rugi cross entropy. Selain itu, telah dihitung pula nilai akurasi yang menunjukkan persentase jumlah citra sampah plastik yang berhasil diklasifikasikan dengan benar terhadap jumlah seluruh citra sampah plastik pada set pengujian, yaitu akurasi terbaik sebesar 85%. Untuk performa yang lebih baik, peneliti di masa mendatang dapat menerapkan tahap augmentasi seperti penskalaan acak, pergeseran acak, dan lain sebagainya pada data pelatihan.

Daftar Pustaka

- [1] K. Özkan, S. Ergin, S. Işık, and I. Işikli, "A new classification scheme of plastic wastes based upon recycling labels," *Waste Management*, vol. 35, pp. 29–35, 2015.
- [2] J. Pinto Da Costa, T. Rocha Santos, and A. Duarte, "The environmental impacts of plastics and micro-plastics use , waste and pollution: EU and national measures," *European Union*, no. October, pp. 10–62, 2020.
- [3] B. Jiang, J. Yu, and Y. Liu, "The Environmental Impact of Plastic Waste," *Journal of Environmental & Earth Sciences*, vol. 2, Nov. 2020.
- [4] J. E. Celis, W. Espejo, E. Paredes-Osses, S. A. Contreras, G. Chiang, and P. Bahamonde, "Plastic residues produced with confirmatory testing for COVID-19: Classification, quantification, fate, and impacts on human health," *Science of The Total Environment*, vol. 760, p. 144167, 2021.
- [5] E. Gothai, R. Thamilselvan, P. Natesan, M. Keerthivasan, K. Kabinesh, and D. K. Ruban, "PLASTIC WASTE CLASSIFICATION USING CNN FOR SUPPORTING 3R ' s," in *2022 International Conference on Computer Communication and Informatics (ICCCI)*, 2022.
- [6] Z. Wang, B. Peng, Y. Huang, and G. Sun, "Classification for plastic bottles recycling based on image recognition," *Waste Management*, vol. 88, pp. 170–181, 2019.
- [7] M. L. Henriksen, C. B. Karlsen, P. Klarskov, and M. Hinge, "Vibrational Spectroscopy Plastic classification via in-line hyperspectral camera analysis and unsupervised machine learning," *Vibrational Spectroscopy*, vol. 118, no. November 2021, p. 103329, 2022.
- [8] S. Jiang *et al.*, "Using ATR-FTIR spectra and convolutional neural networks for characterizing mixed plastic waste," *Computers & Chemical Engineering*, vol. 155, p. 107547, 2021.

-
- [9] H. Ritchie and M. Roser, “Plastic Pollution,” *Our World in Data*, 2018.
- [10] H. I. Abdel-Shafy and M. S. M. Mansour, “Solid waste issue: Sources, composition, disposal, recycling, and valorization,” *Egyptian Journal of Petroleum*, vol. 27, no. 4, pp. 1275–1290, 2018.
- [11] J. Hopewell, R. Dvorak, and E. Kosior, “Plastics recycling: challenges and opportunities.,” *Philosophical transactions of the Royal Society of London. Series B, Biological sciences*, vol. 364, no. 1526, pp. 2115–2126, Jul. 2009.
- [12] C. Szegedy *et al.*, “Going deeper with convolutions,” in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2015, vol. 07-12-June, pp. 1–9.
- [13] Y. Jusman, I. M. Firdiantika, D. A. Dharmawan, and K. Purwanto, “Performance of multi layer perceptron and deep neural networks in skin cancer classification,” in *2021 IEEE 3rd Global Conference on Life Sciences and Technologies (LifeTech)*, 2021, pp. 534–538.
- [14] L. Listyalina and I. Mustiadi, “Accurate and Low-cost Fingerprint Classification via Transfer Learning,” in *2019 5th International Conference on Science in Information Technology: Embracing Industry 4.0: Towards Innovation in Cyber Physical System, ICSITech 2019*, 2019, pp. 27–32.
- [15] R. B. Girshick, J. Donahue, T. Darrell, and J. Malik, “Rich feature hierarchies for accurate object detection and semantic segmentation,” *CoRR*, vol. abs/1311.2, 2013.
- [16] J. Redmon, S. K. Divvala, R. B. Girshick, and A. Farhadi, “You Only Look Once: Unified, Real-Time Object Detection,” *CoRR*, vol. abs/1506.0, 2015.
- [17] L. Listyalina, I. Mustiadi, and D. A. Dharmawan, “Joint Dice and Intersection over Union Losses for Deep Optical Disc Segmentation,” in *2020 3rd International Conference on Biomedical Engineering (IBIOMED)*, 2020, pp. 49–54.
- [18] D. A. Dharmawan, D. Li, B. P. Ng, and S. Rahardja, “A New Hybrid Algorithm for Retinal Vessels Segmentation on Fundus Images,” *IEEE Access*, vol. 7, pp. 41885–41896, 2019.
- [19] D. Li, D. A. Dharmawan, B. P. Ng, and S. Rahardja, “Residual U-Net for Retinal Vessel Segmentation,” in *2019 IEEE International Conference on Image Processing (ICIP)*, 2019, pp. 1425–1429.
- [20] G. Huang, Z. Liu, and K. Q. Weinberger, “Densely Connected Convolutional Networks,” *CoRR*, vol. abs/1608.0, 2016.
-

- [21] K. He, X. Zhang, S. Ren, and J. Sun, “Deep Residual Learning for Image Recognition,” in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 770–778.