

Klik disini untuk menuliskan kategori naskah

Klasifikasi Mikroplastik Menggunakan Convolutional Neural Network Dengan Pre-Trained Model MobilenetV2

Risman Irwan¹, Abdul Haris Muhammad², Junaidi Noh³

¹ Fakultas Teknik, Program Studi Teknik Informatika, Universitas Muhammadiyah Maluku Utara, Ternate, Indonesia

² Fakultas Teknik, Program Studi Teknik Informatika, Universitas Muhammadiyah Maluku Utara, Ternate, Indonesia

³ Fakultas Teknik, Program Studi Teknik Informatika, Universitas Muhammadiyah Maluku Utara, Ternate, Indonesia

INFORMASI ARTIKEL

Diterima Redaksi: 00 Januari 00

Revisi Akhir: 00 Februari 00

Diterbitkan Online: 00 Maret 00

KATA KUNCI

Mikroplastik; Computer Vision; Deep Learning; Pre-Trained Model; MobileNetV2

KORESPONDENSI

Phone: +62 (0751) 12345678

E-mail: rismanirwan0603@gmail.com

A B S T R A K

Penelitian ini menerapkan teknologi visi komputer di bidang lingkungan untuk mengklasifikasi jenis mikroplastik. Mikroplastik merupakan sampah plastik berukuran kecil (kurang dari 5 mm) yang berbahaya bagi lingkungan dan makhluk hidup, namun proses identifikasinya secara manual masih relatif rumit. Perkembangan teknologi computer vision berbasis deep learning memberikan solusi efisien untuk pengenalan citra secara otomatis. Penelitian ini memanfaatkan pre-trained model MobileNetV2 dengan kustomisasi arsitektur CNN yang disesuaikan untuk mengklasifikasi jenis mikroplastik. Dataset diperoleh dari platform Roboflow yang terdiri dari 4 kelas, yaitu fiber, film, fragment, dan pellet, dengan pembagian 3.800 data training dan 876 data testing. Pelatihan model menggunakan PyTorch menghasilkan akurasi sebesar 0,9932 dan loss sebesar 0,0439 pada tahap pertama, serta akurasi sebesar 0,9943 dan loss sebesar 0,0542 pada tahap kedua.

PENDAHULUAN

Permasalahan sampah tidak terlepas dari aktivitas manusia. Menurut laporan World Bank "What a Waste 2.0," setiap tahun di seluruh dunia terdapat 2,01 miliar ton sampah padat perkotaan yang dihasilkan. Bank Dunia memperkirakan jumlah sampah di seluruh dunia akan naik hingga 70%, sehingga mencapai 3,4 miliar ton setiap tahun pada tahun 2050[1]. Plastik kini sudah jadi bagian yang tidak bisa dipisahkan dari kehidupan manusia saat ini. Banyak barang yang digunakan orang dalam kehidupan sehari-hari biasanya terbuat dari plastik. Pada awal diciptakannya, plastik sering digunakan untuk menggantikan bahan-bahan alami agar barang-barang bisa tahan lebih lama.[2]. Produksi plastik yang sangat masif menyebabkan masalah besar bagi lingkungan dan makhluk hidup. Indonesia menjadi salah satu penyumbang limbah plastik ke laut terbesar kedua di dunia dengan estimasi 0,48 hingga 1,29 MMT. Kondisi ini merupakan dampak langsung dari lonjakan produksi plastik global yang mengakibatkan masuknya 4,8 hingga 12,7 juta metrik ton sampah plastik ke perairan laut secara global[3]. Di Indonesia, setiap hari dihasilkan sekitar 175.000 ton sampah, sehingga menghadapi masalah besar dalam mengelola sampah dengan efisien dan berkelanjutan.[4][5].

Sampah plastik tidak mengalami penguraian secara alami di alam, melainkan akan terdegradasi menjadi berukuran sangat kecil. Ukuran mikroplastik lebih kecil dari 5 mm[6]. Oleh karena ukurannya yang kecil dan penggunaan yang plastik yang sangat masif menyebabkan mikroplastik berada di sekitar kita tanpa kita sadari. Sebuah studi yang dilakukan oleh Universitas Airlangga mendapati hasil sebanyak 94% sample mengandung mikroplastik dengan total sample sebanyak 100 sample ikan laut[7]. Ini menandakan bahwa dampak dari mikroplastik bisa masuk ke dalam ekosistem dan rantai makanan. Mikroplastik dapat dikelompokkan kedalam 5 jenis berdasarkan bentuk, yaitu film, fragmen, fiber, pellet, dan

foam[6]. Mikroplastik dapat dijumpai di lokasi yang berbeda, yang mengindikasikan pola pencemaran perairan di Indonesia[8].

Industri manufaktur saat ini terkait dengan polusi mikroplastik, yang telah menjadi masalah lingkungan besar, dengan berbagai laporan menunjukkan keberadaannya di lingkungan perairan serta daratan di berbagai belahan dunia. Pencemaran mikroplastik semakin parah karena kumpulan polimer polietilena dari berbagai kegiatan industri, seperti pembuangan sampah medis dan farmasi.[9]. Mikroplastik merupakan ancaman serius bagi lingkungan dan manusia. Partikel plastik berukuran sangat kecil ini dapat masuk ke dalam tubuh manusia secara tidak sengaja akibat mengonsumsi makanan yang mengandung mikroplastik yang sudah terlanjur masuk ke dalam rantai makanan[8]. Beberapa logam yang mencemari air akibat kontaminasi sampah plastik, seperti logam berat dan bahan kimia organik, dapat meracuni manusia yang mengonsumsi biota laut yang terkontaminasi[10]. Akumulasi mikroplastik dalam tubuh organisme dapat menyebabkan gangguan pencernaan, perubahan perilaku makan, dan penurunan kesehatan secara keseluruhan[11]. Mikroplastik juga dapat berperan sebagai vektor bagi zat-zat kimia berbahaya, seperti polutan organik persisten (POP) dan logam berat, yang dapat teradsorpsi oleh permukaan mikroplastik dan kemudian ditransfer ke organisme yang mengonsumsinya[11]. Selain di laut, mikroplastik juga terdapat di dalam tanah. Mikroplastik yang terakumulasi di tanah pertanian juga dapat mempengaruhi kualitas tanah dan ketersediaan nutrisi bagi tanaman, yang pada akhirnya dapat mengurangi hasil panen dan kesehatan tanaman[11].

Perkembangan teknologi kecerdasan buatan sangat masif di era sekarang, deep learning sendiri adalah salah satu sub-bidang dari kecerdasan buatan, yang melatih sebuah model menggunakan neuron-neuron yang saling terhubung. Deep learning digunakan karena mampu menyelesaikan permasalahan yang lebih kompleks seperti yang tidak dapat diselesaikan oleh machine learning konvensional[12]. Deep learning banyak digunakan untuk mengidentifikasi objek gambar dikarenakan kemampuannya dalam menginterpretasikan data dengan meniru mekanisme kerja otak manusia[13]. Dengan memanfaatkan teknologi kecerdasan buatan, kita dapat membangun sebuah model yang dapat mengklasifikasikan jenis-jenis mikroplastik secara otomatis. Convolutional Neural Network (CNN) adalah jaringan saraf tiruan feed-forward dengan struktur hierarkis[14] yang nantinya dapat digunakan untuk klasifikasi citra objek[15]. Setiap layer berfungsi sebagai feature learning yang dapat mempelajari fitur gambar secara otomatis dan setiap layer akan menghasilkan sebuah feature map. CNN digunakan karena mengandalkan pembagian bobot untuk mengurangi parameter pelatihan dan mencegah overfitting. CNN menonjol dalam identifikasi objek dan deteksi pola visual yang kompleks, mengekstrak elemen-elemen penting dari gambar sambil meningkatkan efisiensi komputasi[16]. Mekanisme ekstraksi fitur pada CNN memungkinkan model untuk mengenali berbagai tingkatan pola visual pada gambar, mulai dari fitur sederhana hingga karakteristik yang rumit. Hal ini menjadikan arsitektur CNN sangat ideal untuk menangani tantangan klasifikasi citra bernilai kompleksitas tinggi[17]. Model CNN diimplementasikan dan dilatih menggunakan data latih untuk mengenali pola visual yang spesifik pada citra dari masing-masing[18].

Deep Learning menyediakan banyak pre-trained model atau arsitektur yang dapat digunakan untuk mengerjakan tugas komputer vision. Pre-trained sendiri merupakan model arsitektur yang telah dilatih menggunakan ribuan data sebelumnya. Pre-trained model tidak terlepas dari transfer learning. Transfer learning merupakan cara yang dilakukan dalam deep learning agar model belajar dengan data yang berbeda namun dalam lingkup tugas yang sama, misalnya dalam menjalankan tugas visi komputer[12]. Beberapa tahun belakangan ini, banyak ahli telah memperkenalkan beragam algoritma untuk otomatisasi dan klasifikasi[19]. Beragam arsitektur yang dikembangkan untuk menjalankan tugas klasifikasi diantaranya adalah AlexNet, LeNet, MobileNetV2, ResNet50, dan lain-lain. Pada penelitian ini pre-trained model yang digunakan MobileNetV2, model ini dipilih karena MobileNetV2 merupakan model yang dikembangkan oleh Google yang memiliki arsitektur yang ringan[13].

Pada penelitian sebelumnya berjudul “Automated micro-plastic detection and classification using deep convolution neural network pre-trained models and transfer learning” menggunakan Pre-trained model besar, model pre-trained yang digunakan yaitu EfficientB7, InceptionV3, ResNet50V2, dan MobilenetV3Large, dengan beberapa data augmentasi tambahan untuk menambah variasi data, sample mikroplastik yang diuji pada penelitian sebelumnya 84 dengan total 3 kelas, yaitu Bead, Fiber, dan Fragment[9].

Penelitian ini bertujuan untuk menganalisis performa model berdasarkan skenario dan mengevaluasi performa model dengan membandingkan dua skenario pelatihan yaitu pelatihan dengan menggunakan augmentasi data dan menggunakan augmentasi data dengan indikator metrik seperti Accuracy, Precision, Recall, F1-Score, dan Loss, Penelitian ini juga

menerapkan teknologi kecerdasan buatan di bidang lingkungan dengan menyediakan solusi berbasis computer vision dan deep learning yang efisien dan presisi untuk membantu mempermudah proses identifikasi mikroplastik.

Penelitian ini diharapkan memberikan manfaat teoritis dan pengembangan ilmu komputer dan memberikan kontribusi akademis terkait penerapan transfer learning dan pengaplikasian teknologi kecerdasan buatan di bidang lingkungan.

TINJAUAN PUSTAKA

Mikroplastik

Frias & Nash (2019) mendefinisikan mikroplastik sebagai “segala partikel solid sintetis atau matriks polimer, dengan bentuk regular atau ireguler berukuran 1µm sampai 5mm, baik diproduksi secara primer maupun sekunder, yang tidak dapat larut dalam air.” Mikroplastik dapat berupa mikroplastik sekunder, yaitu berasal dari degradasi dan abrasi makroplastik, maupun berupa mikroplastik primer, yang memang didesain dari awal berukuran kecil, seperti glitter pada kosmetik dan microbeads pada scrubber[20].

Mikroplastik didefinisikan sebagai partikel plastik yang berukuran kurang dari 5 milimeter dan telah banyak ditemukan di berbagai lingkungan perairan, baik di ekosistem laut maupun air tawar. Berdasarkan bentuk fisiknya, mikroplastik dapat diklasifikasikan menjadi tiga jenis utama, yaitu serat (fibers), fragmen (fragments), dan lapisan tipis (films) [8].

Dalam jurnal ” Pengaruh Limbah Mikroplastik Terhadap Organisme dan Upaya Penanganannya” Sumber mikroplastik terdapat dua yaitu Primary MicroPlastics merupakan plastik yang diproduksi secara mikroskopis yang terlepas ke lingkungan dalam bentuk kecil partikulat baik sengaja maupun tidak disengaja, mikroplastik yang digunakan dalam produk seperti agen penggosok peralatan mandi dan kosmetik serta Secondary Microplastics yang merupakan mikroplastik yang berasal dari degradasi plastik dengan ukuran lebih besar menjadi fragmen plastik yang lebih kecil. Hal ini terjadi melalui fotodegradasi dan proses pelapukan limbah plastik[11]

Deep Learning

Menurut merupakan sub bidang dari kecerdasan buatan yang digunakan untuk menjalankan tugas yang lebih kompleks daripada *machine learning* konvensional, keuntungan dari deep learning terletak pada ekstraksi fitur yang dilakukan secara otomatis, atau yang biasa dikenal sebagai *feature learning*, *deep learning* juga sangat lihai ketika belajar menggunakan data yang banyak, berbeda dengan machine learning konvensional yang cenderung stagnan di titik tertentu ketika dilatih dengan banyak data[12].

Deep learning banyak digunakan untuk mengidentifikasi objek gambar dikarenakan kemampuannya dalam menginterpretasikan data dengan meniru mekanisme kerja otak manusia[13].

Convolutional Neural Network

Convolutional Neural Network (CNN) merupakan sebuah algoritma deep learning yang dapat menerima input berupa citra dan dengan menetapkan bobot dan bias untuk menentukan perbedaan sifat dari berbagai gambar. Menurut Sewak Mohit, Karim Rezaul dan Pujari Pradeep, (2018) *CNN* merupakan jenis jaringan saraf *multilayer* yang sangat khusus. *CNN* dirancang untuk mengenali pola visual langsung dari gambar dengan pemrosesan minimal[12].

Menurut Liu(2018) Struktur dari jaringan saraf konvolusi terdiri dari lapisan pra-pemrosesan, lapisan konvolusi, lapisan penyatuan, dan lapisan klasifikasi[12].

Transfer Learning


Transfer learning merupakan sebuah metode yang digunakan dalam deep learning untuk melatih sebuah data, transfer learning bermaksud mengambil dan menggunakan pengetahuan dari model yang sudah dilatih sebelumnya untuk kemudian dicoba menggunakan data yang baru, namun masih dalam menjalankan tugas yang sama. Beberapa model yang sering digunakan untuk menjalankan tugas klasifikasi gambar pada bidang computer vision yaitu AlexNet, LeNet, ResNet, MobileNet, EfficientNet, sedangkan pada tugas deteksi objek seperti YOLO, Faster R-CNN, dan lain-lain.[12]

Heading pada level kedua dituliskan dengan *boldface italics* dengan menggunakan huruf besar dan huruf kecil. *Heading* dituliskan rata kiri.

METODOLOGI

Kerangka Konsep Penelitian

Kerangka konsep penelitian dibutuhkan dalam proses penelitian agar menghasilkan penelitian yang naik dan sesuai dengan sasaran penelitian. Oleh karena itu diperlukan sebuah kerangka konsep yang dibuat dalam bentuk diagram. Adapun diagram kerangka konsep sebagai berikut:




Gambar 1 Kerangka Konsep Penelitian

Pada Gambar 1. Kerangka konsep diatas menggambarkan sebuah alur pemahaman yang dimulai dari permasalahan hingga penyelesaian solusi dengan mengimplementasikan teknologi kecerdasan buatan terutama *deep learning* dengan algoritma *Convolutional Neural Network* untuk mengidentifikasi jenis mikroplastik.

Setelah mengidentifikasi masalah dan cara solusi dalam menanganinya, selanjutnya penelitian dilakukan berdasarkan diagram alur penelitian Gambar 2 di bawah ini:

Alur Penelitian

Pada penelitian ini mengikuti alur dari penelitian sebelumnya, berikut merupakan alur dari penelitian yang berjudul "Automated micro-plastic detection and classification using deep convolution neural network pre-trained models and transfer learning" dengan sedikit penyesuaian.



Gambar 2. Alur Penelitian

Tahapan yang dilalui dalam penelitian, pembangunan konsep, atau penyelesaian kasus, dituliskan pada bagian metodologi.

Diagram alur penelitian pada Gambar 2 menggambarkan alur penelitian dari proses membangun sebuah model untuk mengidentifikasi jenis mikroplastik. Proses penelitian dimulai dari simbol "Mulai" yang menandakan alur penelitian telah dimulai. Langkah selanjutnya adalah proses akuisisi data.

Tahap akuisisi data merupakan proses awal, dimana data dikumpulkan dari platform internet. Data didapatkan dari Roboflow, sebuah platform online yang berisi banyak data dan model yang biasa digunakan untuk pengembangan model deep learning terutama di bidang computer vision. Dari hasil pengumpulan data didapatkan data sebanyak 4676

Tahapan selanjutnya adalah preprocessing gambar, tahap ini data akan diolah agar sesuai dengan pre-trained model yang akan dipakai, preprocessing gambar seperti Resize, untuk menyesuaikan ukuran dan juga ToTensor, untuk mengubah data menjadi tensor agar dapat digunakan.

Tahapan selanjutnya adalah seleksi fitur otomatis menggunakan deep learning. *Deep learning* memiliki keunggulan dalam melakukan seleksi fitur atau *fitur extraction*. *Deep learning* mampu melakukan ekstraksi fitur secara otomatis atau disebut feature learning, dikarenakan model dari *CNN* yang memiliki neuron yang saling terhubung[12]. Pada tahap ini model *CNN* akan diperlukan sebagai *hidden layer* yang berfungsi untuk mengekstrak fitur dari gambar secara otomatis. *CNN* terdiri dari layer-layer saling terhubung, layer-layer ini menjalankan fungsi matematis didalamnya untuk menyeleksi fitur, misalnya pada lapisan konvolusi memiliki perhitungan sebagai berikut:

$$Mx = \frac{Ix - Kx}{Sx}, My = \frac{Iy - Ky}{Sy} \quad (1)$$

Keterangan:

(Mx, My) = Ukuran peta

(Ix, Iy) = Ukuran input

(Ky, Kx) = Ukuran kernel secara terpisah

(Sx, Sy) = Menunjukkan *stride* pada kolom dan baris

Pembagian data merupakan tahapan yang penting dalam melatih model, data akan dibagi menjadi data training dan data testing, data yang dikumpulkan telah dibagi dalam folder data training dan testing ketika diakuisisi, data training yang digunakan sebanyak 3800 sekitar kurang lebih 80% dari total data, dan testing sebesar 876 sekitar kurang lebih 20% dari total keseluruhan data.

Proses selanjutnya adalah memilih pre-trained model yang digunakan untuk melatih model. Proses ini menggunakan teknik tranfer learning dalam melatih model, pre-trained model yang digunakan yaitu MobileNetV2, yang merupakan model untuk melakukan tugas klasifikasi citra.

Kustomisasi layer adalah tahapan dimana pre-trained model yang digunakan akan diubah dan dimodifikasi sesuai dengan kebutuhan dan jumlah data yang ada. Pada tahap ini model layer akan dibekukan, dan hanya berfungsi sebagai hidden layer. Kustomisasi hanya dilakukan pada layer klasifikasi untuk penyesuaian susai dengan jumlah kelas.

Pada penelitian ini menggunakan 2 skenario pelatihan, pelatihan menggunakan augmentasi data, dan pelatihan tanpa menggunakan augmentasi data. Dalam proses pelatihan terdapat dua macam proses yakni propagasi maju dan propagasi mundur. Pada proses pelatihan diperlukan sebuah fungsi loss dan fungsi pengoptimalan. Kedua fungsi itu diperlukan untuk mengukur seberapa bagus model dalam belajar, serta melakukan *update parameter* pada saat pelatihan. Nilai *learning-rate* sangat berpengaruh pada proses pelatihan untuk menghasilkan momentum yang diperlukan dalam proses pembelajaran[12]. Fungsi loss yang digunakan yaitu Cross Entropy Loss yang merupakan fungsi loss paling umum yang digunakan dalam klasifikasi citra. Cross Entropy Loss dapat dihitung dengan persamaan dibawah ini:

$$\text{Cross Entorpy} = - \sum_{i=1}^{i=n} y_{true\ i} \cdot \log(y_{pred\ i}) \quad (2)$$

Keterangan:

$y_{true\ i}$ = Nilai keluaran asli pada indeks ke- i (biasanya 0 atau 1 dari *vector one hot encoding*)

$y_{pred\ i}$ = Nilai hasil prediksi pada indeks ke- i (biasanya 0 atau 1 dari *vector one hot encoding*)

Fungsi pengoptimalan yang digunakan adalah *Adam (Adaptive Moment Estimation)* adalah salah satu varian metode optimasi yang digunakan untuk mengubah learning-rate secara adaptif seperti gradient descent stokastik dengan momentum. Persamaan *Adam* dapat ditulis sebagai berikut:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (3)$$

$$v_t = \beta_2 m_{t-1} + (1 - \beta_2) g_t^2 \quad (4)$$

Oleh (Kingma, 2015) diperlihatkan bahwa kedua estimasi atas bias ke arah 0 terutama pada saat iterasi awal optimasi, sehingga diperkenalkan suatu rumus koreksi bias sebagai berikut:

$$m'_t = \frac{m_t}{1 - \beta_1^2} \quad (5)$$

$$v'_t = \frac{v_t}{1 - \beta_2^2} \quad (6)$$

Kemudian update term dapat ditentukan dengan rumus persamaan berikut:

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{v'_t + \epsilon}} m'_t \quad (7)$$

Keterangan: m_t = Estimasi momen pertama v_t = Estimasi momen kedua g = Gradien β = Bias θ = Parameter

Tahap selanjutnya adalah pengujian model. Pada tahap ini model yang telah dilatih akan diuji untuk menggunakan data testing untuk melihat seberapa bagus model dalam melakukan klasifikasi.

Evaluasi metrik merupakan tahapan untuk menilai dan mengevaluasi seberapa bagus performa model, metrik pelatihan yang digunakan antara lain *Precision Score*, *Recall Score*, *Loss*, *Accuracy*, *F1-Score*, *Classification Report* hingga *Confusion Matrix*. Beberapa istilah dalam Metrik evaluasi seperti *TP (True Positive)*, *FP (False Positive)*, *FN (False Negative)*, dan *TN (True Negative)*. Metrik evaluasi dapat dihitung menggunakan persamaan berikut:

$$Akurasi = \frac{TP+TN}{TP+TN+FN+FP} = \frac{TP+TN}{P+N} \quad (8)$$

$$Presisi = \frac{TP}{FP+TP} \quad (9)$$

$$Recall = \frac{TP}{TP+FN} \quad (10)$$

$$F1 - Score = \frac{2 \times Presisi \times Recall}{Presisi + Recall} \quad (11)$$

HASIL DAN PEMBAHASAN

Data yang digunakan dalam penelitian ini berjumlah 4676 yang diambil dari platform *Roboflow*, sebuah *online platform* yang menyimpan banyak data dan model untuk pengembangan *deep learning* terutama di bidang *computer vision*, data kemudian diolah dengan menggunakan *normalize* dan juga *transform* agar data tersebut dapat digunakan pada *pre-trained model* untuk kemudian dilatih. Proses pelatihan menggunakan dua skenario, skenario pertama yaitu pelatihan model tanpa menggunakan augmentasi data, dan skenario adalah pelatihan model dengan menggunakan augmentasi data.

Import Dataset

Setelah proses pengumpulan data selesai, tahap selanjutnya adalah mengimport data ke dalam Google Colab. Dataset yang di akuisisi awalnya berbentuk file *zip*, sehingga harus diekstrak terlebih dahulu, data yang di akuisis terbagi ke dalam dua folder, yaitu folder untuk data *training*, dan *testing*, setelah data berhasil diekstrak akan dilakukan proses pre-processing dan pembuatan dataset menggunakan *torchvision*. Dalam pembuatan dataset menggunakan *torchvision* kita harus menggunakan pustaka *ImageFolder* yang berisi *root* dari data dan juga *transforms* untuk mengubah data menjadi *tensor* pada *root* atau *folder* data yang sudah diimpor.

Setelah membuat dataset menggunakan *torchvision* langkah selanjutnya adalah membuat *dataloader* menggunakan *torch*. Pembuatan *dataloader* diperlukan untuk melakukan *batching*, *shuffling* dan juga mengurangi komputasi. Dalam pembuatan *dataloader*, terdapat hyperparameter seperti *batch size*, dan *num worker* yang dapat digunakan. Pada penelitian ini *batch size* yang digunakan pada penelitian ini yaitu 32, *hyperparameter* ini dipilih karena banyak dan sering digunakan pada penelitian lain. Dan juga hyperparameter lain seperti *num worker* menggunakan *default* langsung dari yang diberikan oleh Google Colab.

Model

Setelah seluruh pre-processing sudah selesai, langkah selanjutnya adalah membuat model klasifikasi menggunakan *pre-trained model*. *Pre-trained* yang dipilih yaitu *MobileNetV2*. Proses matematis dari *MobileNetV2*

```

=====
Total params: 3,504,872
Trainable params: 3,504,872
Non-trainable params: 0
Total mult-adds (Units.GIGABYTES): 9.63
=====
Input size (MB): 19.27
Forward/backward pass size (MB): 3419.45
Params size (MB): 14.02
Estimated Total Size (MB): 3452.74
=====

```

Gambar 1 Parameter MobileNetV2 Sebelum Modifikasi

Pada Gambar 1 di atas menampilkan parameter dari model MobileNetV2 sebelum dimodifikasi. Modifikasi diperlukan untuk menyesuaikan model dengan data, pada penelitian ini modifikasi hanya dilakukan pada bagian layer klasifikasi atau pada bagian *Fully-Connected Layer*.

```

=====
Total params: 2,228,996
Trainable params: 5,124
Non-trainable params: 2,223,872
Total mult-adds (Units.GIGABYTES): 9.59
=====
Input size (MB): 19.27
Forward/backward pass size (MB): 3419.19
Params size (MB): 8.92
Estimated Total Size (MB): 3447.38
=====

```

Gambar 2 Parameter MobileNetV2 Setelah Modifikasi

Pada Gambar 2 di atas menampilkan model *MobileNetV2* yang telah dimodifikasi, hasil yang ditampilkan terdapat perubahan pada total params yang awalnya berkisar 3,504,876 parameter, turun hingga menjadi 2,228,996. Hal ini dikarenakan MobileNetV2 awalnya dilatih dengan menggunakan 1000 kelas, sementara itu modifikasi yang dilakukan pada bagian *Fully-Connected Layer* mengubah 1000 kelas menjadi hanya 4 kelas, mengikuti banyaknya kelas yang ada pada penelitian ini, kelas yang digunakan yaitu *fiber*, *fragment*, *pellet*, dan *film*.

Setelah membuat dan memodifikasi model, langkah selanjutnya adalah membuat *loss function* dan juga *optimizer*. *Loss Function* yang digunakan yaitu *optimizer*. Kedua fungsi tersebut diperlukan agar model dapat belajar dengan baik. *Loss Function* yang digunakan adalah *CrossEntropyLoss* yang umum digunakan dalam melatih model untuk tugas klasifikasi. *Optimizer* yang digunakan adalah *Adam*, dengan nilai *learning rate* 0,001. Adam digunakan karena memiliki kemampuan yang adaptif[12].

Training

Dalam proses pelatihan, terdapat perhitungan matematis di dalamnya, dalam proses ini pula terdapat proses propagasi maju dan propagasi mundur serta perhitungan terhadap *loss function* yang digunakan. Persamaan matematis dari ketiga proses tersebut dapat dilihat pada persamaan di bawah ini:

Perhitungan propagasi maju

$$y = w \cdot x + b \quad (12)$$

Keterangan:

y = nilai yang diprediksi

w = bobot

x = input

b = bias

kemudian menghitung turunan dari fungsi aktivasi

$$\begin{aligned} \text{relu} &= \max(0, x) \\ \text{if } x > 0, \frac{\partial(\text{relu})}{\partial x} &= 0 \end{aligned} \quad (13)$$

Keterangan:

x = nilai input

Kemudian menghitung *Loss Function*, *loss function* yang digunakan adalah *CrossEntropyLoss* sehingga dapat dirumuskan menggunakan persamaan di bawah ini:

$$\text{Cross Entorpy} = - \sum_{i=1}^{i=n} y_{true\ i} \cdot \log(y_{pred\ i}) \quad (14)$$

Kemudian menghitung propagasi balik menggunakan aturan rantai. Aturan rantai menggunakan aturan yang dapat digunakan untuk melakukan bobot pada proses propagasi balik[12]. Untuk proses update bobot dapat menggunakan rumus berikut:

$$w_2 = w_2 - n \frac{\partial E}{\partial w_2} \quad (15)$$

Dengan menggunakan prinsip aturan rantai dapat dihitung menggunakan persamaan berikut:

$$\frac{\partial E}{\partial w_2} = \frac{\partial E}{\partial a_2} \frac{\partial a_2}{\partial z_2} \frac{\partial z_2}{\partial w_2} \quad (16)$$

Pada penelitian ini menggunakan dua skenario pelatihan, pelatihan pertama adalah pelatihan tanpa menggunakan augmentasi data, dengan masing-masing dilatih sebanyak 17 *epoch*. Pada skenario pertama ini hanya menggunakan *normalize* dan *transforms*. Pada skenario kedua, diterapkan beberapa teknik augmentasi data spasial dan fotometrik untuk meningkatkan variasi citra mikroplastik tanpa mengubah nilai labelnya. Teknik yang digunakan meliputi:

1. *Random Horizontal & Vertical Flip*: Memutar citra secara horizontal dan vertikal dengan probabilitas 0,5. Teknik ini efektif meniru variasi orientasi mikroplastik saat ditangkap oleh kamera di lapangan.
2. *Random Rotation*: Melakukan rotasi acak pada rentang sudut tertentu (0° hingga 360°) guna memastikan model invariant terhadap arah rotasi partikel mikroplastik.
3. *Random Adjust Sharpness & Autocontrast*: Mengubah tingkat ketajaman dan kontras citra secara adaptif untuk mensimulasikan perbedaan kualitas pencahayaan serta efek pembiasan cahaya pada sampel mikroskopis.

Penerapan kombinasi augmentasi ini secara matematis mengubah distribusi input $x \rightarrow T(x)$, di mana T adalah fungsi transformasi stokastik. Hal ini memaksa model untuk mempelajari fitur intrinsik dari bentuk morfologi mikroplastik (seperti tekstur dan lekukan batas area) alih-alih sekadar menghafal piksel latar belakang.

Pada skenario pertama menghasilkan metrik evaluasi yang sangat bagus, metrik evaluasi seperti *presicion*, *f1-score*, *recall*, dan *accuracy*, serta menghasilkan grafik *confusion matrix* yang bagus yang menunjukkan diagonal yang menandakan bahwa model sangat baik dalam menebak dan mengklasifikasi jenis mikroplastik grafik *confusion matrix* dan tabel metrik evaluasi dapat dilihat di bawah ini.


Tabel 1 Metrik Evaluasi Tanpa Augmentasi

<i>Metrics</i>	<i>Score</i>	<i>Macro Avg</i>	<i>Weighted Avg</i>
<i>Precision</i>	0.9932	0.9930	0.9932
<i>Recall</i>	0.9932	0.9932	0.9932

<i>F1-Score</i>	0.9931	0.9931	0.9931
<i>Accuracy</i>	0.9932	-	-
<i>Loss</i>	0.0439	-	-


Tabel 2 Metrik Evaluasi Per Kelas Tanpa Augmentasi

<i>Class</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
<i>fiber</i>	0.9958	0.9958	0.9958
<i>Film</i>	1.0000	0.9822	0.9910
<i>Fragment</i>	0.9851	1.0000	0.9925
<i>Pallet</i>	0.9943	1.0000	0.9977



Gambar 3 Confusion Matrix Skenario Pertama

Evaluasi metrik pada skenario pertama menggunakan jenis weighted, dari hasil metrik pelatihan dan grafik *confusion matrix* yang dihasilkan dmenampilkan hasil yang sangat bagus, model menamapilkan diagonal ketika menebak dan mengklasifikasi jenis mikroplastik, hal ini menunjukan performa model yang bagus. Namun, ada indikasi terjadinya gejala overfitting pada skenario pertama ini, hal ini dikarenakan pada pelatihan ini tidak menggunakan augmentasi data yang menyebabkan model terus melihat data yang sama secara berulang. Untuk mengetahui adanya apakah model mengalami overftting atau tidak, peninjauan terhadap grafik pelatihan yang dihasilkan harus diperhatikan. Grafik dari pelatihan model tanpa menggunakan augmentasi data dapat dilihat pada Gambar 2 di bawah ini.



Gambar 4 Grafik Pelatihan Tanpa Augmentasi Data

Pada Gambar 4 di atas dapat dilihat bahwa grafik dari *train loss* lebih rendah daripada *test loss*, hal ini jelas menunjukkan adanya gejala *overfitting*, dapat dilihat bahwa awal mula *overfitting* terjadi pada epoch ke-6 di mana *test loss* cenderung mengalami peningkatan, hingga pada epoch ke-14 *test loss* mencapai nilai 0,0449. Sementara itu *train loss* mengalami penurunan hingga mencapai titik terendahnya pada epoch ke-14 dengan nilai 0,0302. Fenomena ini jelas menandakan model mengalami *overfitting*, hal ini dikarenakan data yang kurang bervariasi sehingga model hanya melihat data yang sama secara berulang, sehingga model hanya menghafal sehingga terjadi peningkatan pada data uji.


Pada skenario kedua menggunakan augmentasi data menunjukkan nilai metrik evaluasi, dan *confusion matrix* yang mirip dengan skenario pertama, hasil dari metrik evaluasi dan grafik *confusion matrix* dapat dilihat di bawah ini.

Tabel 3 Metrik Evaluasi Dengan Augmentasi

<i>Metrics</i>	<i>Score</i>	<i>Macro Avg</i>	<i>Weighted Avg</i>
<i>Precision</i>	0.9941	0.9941	0.9943
<i>Recall</i>	0.9943	0.9945	0.9943
<i>F1-Score</i>	0.9943	0.9943	0.9943
<i>Accuracy</i>	0.9943	-	-
<i>Loss</i>	0.0418	-	-

Tabel 4 Metrik Evaluasi Per Kelas Dengan Augmentasi


<i>Class</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
<i>fiber</i>	0.9917	0.9958	0.9938
<i>Film</i>	0.9955	0.9778	0.9865
<i>Fragment</i>	0.9801	0.9949	0.9875
<i>Pallet</i>	0.9953	0.9953	0.9953



Gambar 5 Confusion Matrix Skenario Kedua


Pada skenario kedua terdapat perbedaan pada nilai akurasi yang sedikit lebih tinggi daripada skenario pertama, sementara pada bagian loss skenario pertama masih lebih unggul karena masih lebih rendah daripada skenario kedua. Pada skenario

kedua ini menghasilkan grafik pelatihan yang lebih baik daripada skenario pertama, sama halnya dengan skenario pertama, evaluasi metrik yang digunakan adalah *weighted*, jika pada skenario pertama mengalami *overfitting*, skenario kedua mendapati hasil yang *good fit*. Hal ini terjadi karena penggunaan augmentasi data yang menyebabkan model melihat banyak variasi data selama proses pelatihan. Grafik pelatihan dapat dilihat pada gambar 6 di bawah ini.



Gambar 6 Grafik Pelatihan Skenario Kedua

Pada grafik di atas menampilkan proses training yang cukup bagus dimana tidak terdapat tanda atau gejala *overfitting* pada akhir pelatihan. Hal ini menunjukkan bahwa pelatihan dengan augmentasi data pada penelitian ini menghasilkan model yang sangat bagus dalam berlatih. Oleh karena itu model sangat bagus dalam memprediksi serta memiliki tingkat probabilitas yang tinggi dalam melakukan klasifikasi.



Gambar 7 Hasil Klasifikasi Skenario Kedua

Dalam pengujian keseluruhan model, data yang digunakan berasal dari repository dataset terbuka seperti mendeley[21]. Dapat dilihat bahwa hasil klasifikasi memiliki nilai probabilitas yang tinggi mencapai 0.9340 dan 0.7845 dan kelas yang berhasil diprediksi dengan benar atau *true positive*.

Tabel perbandingan antara model dengan skenario pertama dan kedua dapat dilihat pada table di bawah ini.

Tabel 3 Perbandingan Metrik Evaluasi

Metrik	Skenario 1	Skenario 2
<i>Precision</i>	0.9932	0.9941
<i>F1-Score</i>	0.9931	0.9943
<i>Recall</i>	0.9932	0.9943
<i>Accuracy</i>	0.9932	0.9943
<i>Loss</i>	0.0439	0.0418

KESIMPULAN DAN SARAN

Pelatihan menggunakan 2 skenario menunjukkan hasil yang lebih unggul didasarkan pada pembacaan visual kurva, pada pelatihan skenario pertama menghasilkan nilai akurasi sebesar 0.9932, dan nilai loss sebesar 0.0439. Sedangkan pada skenario kedua menghasilkan nilai akurasi sebesar 0.9943, dan loss sebesar 0.0418, tidak ada perbedaan jauh antara kedua skenario, namun dari grafik yang dihasilkan, skenario kedua lebih unggul karena menampilkan grafik loss yang lebih sehat.

Terdapat kekurangan dan keterbatasan dalam penelitian ini yang diharapkan dapat ditingkatkan dari penelitian ini, saran untuk penelitian selanjutnya yaitu:

1. Menambah kualitas dan kuantitas data.
2. Bekerja sama dengan organisasi atau yang fokus ke bidang lingkungan terutama mengenai permasalahan mikroplastik.
3. Menggunakan jenis pre-trained model yang lain
4. Deployment model agar lebih mudah diakses oleh banyak orang.

DAFTAR PUSTAKA

- [1] F. O. Valerin, R. Azhari, A. A. Rahmini, A. Rahmayanti, and M. S. Noor, "Edukasi Pengelolaan Sampah dan Pelatihan Pembuatan Ecobrick di Desa Sungai Tabuk Keramat, Kabupaten Banjar," *J. Inov. Pengabd. dan Pemberdaya. Masy.*, vol. 5, no. 1, pp. 175–186, 2025, doi: 10.54082/jipm.816.
- [2] N. P. Decy Arwini, "Sampah Plastik Dan Upaya Pengurangan Timbulan Sampah Plastik," *J. Ilm. Vastuwidya*, vol. 5, no. 1, pp. 72–82, 2022, doi: 10.47532/jiv.v5i1.412.
- [3] M. H. I. Al Muhdhar, I. W. Sumberartha, Z. Hassan, M. S. Rahmansyah, and M. N. Tamalene, "Examination of Microplastic Particles in Reef Fish Food in Ternate Island Waters, Indonesia," *Jordan J. Biol. Sci.*, vol. 14, no. 4, pp. 853–858, 2021, doi: 10.54319/jjbs/140427.
- [4] L. J. Lingga, M. Yuana, N. A. Sari, H. Nur Syahida, and C. Sitorus, "Sampah di Indonesia: Tantangan dan Solusi Menuju Perubahan Positif," *Innov. J. Soc. Sci. Res.*, vol. 4, no. 4, pp. 12235–12247, 2024, [Online]. Available: <https://j-innovative.org/index.php/Innovative>
- [5] H. Faizal Lut, Yuuyun, "Identifikasi Sampah Plastik Menggunakan Algoritma Deep Learning," *J. Ilm. Sist. Inf. dan Tek. Inform.*, 2023, doi: 10.57093/jisti.v6i2.176.
- [6] A. Sulastri, K. P. Utomo, S. V. Febryanti, and D. Fakhra, "Identifikasi Kelimpahan dan Bentuk Mikroplastik pada Sedimen Pantai Kalimantan Barat," *J. Ilmu Lingkung.*, vol. 21, no. 2, pp. 376–380, 2023, doi: 10.14710/jil.21.2.376-380.
- [7] L. Sulistyorini, N. D. Arfiani, M. A. Rizaldi, L. Lutpiatina, and N. I. A. Samad, "Assessment of Microplastic Pollution in Fresh Fish and Pindang Fish and its Potential Health Hazards in Coastal Communities of Banyuwangi Regency, Indonesia," *Nat. Environ. Pollut. Technol.*, vol. 23, no. 3, pp. 1671–1676, 2024, doi: 10.46488/NEPT.2024.v23i03.038.
- [8] C. H. Arhafna, N. Fadhlina, F. Firdus, A. Rizki, and M. Nasir, "Studi Toksikologi: Mikroplastik pada Organisme Perairan dan Resiko terhadap Kesehatan Manusia di Indonesia," *J. Jeumpa*, vol. 12, no. 1, pp. 13–21, 2025, doi: 10.33059/jj.v12i1.11379.
- [9] K. Devipriya, M. Tlija, C. K. Kumar, V. C. Kumar, S. Jana, and C. Jana, "Automated micro-plastic detection and classification using deep convolution neural network pre-trained models and transfer learning," *AIP Adv.*, vol. 15, no. 2, 2025, doi: 10.1063/5.0243976.
- [10] A. Aulia, R. Azizah, L. Sulistyorini, and M. A. Rizaldi, "Literature Review: Dampak Mikroplastik Terhadap Lingkungan Pesisir, Biota Laut dan Potensi Risiko Kesehatan," *J. Kesehat. Lingkung. Indones.*, vol. 22, no. 3, pp. 328–341, 2023, doi: 10.14710/jkli.22.3.328-341.
- [11] A. A. Amanu, A. P. Zahrani, F. A. Ristaatin, A. Riski, and D. O. Radianto, "Pengaruh Limbah Mikroplastik Terhadap Organisme dan Upaya Penanganannya menyebabkan kerusakan pada lingkungan sekitar perairan dan laut, sampah plastik yang tidak secara mikroskopis yang terlepas ke lingkungan dalam bentuk kecil partikulat baik sengaja," *Manufaktur*, vol. 2, no. 2, pp. 12–24, 2024.
- [12] Y. Novanto, *Deep Learning: Teori, Contoh Perhitungan, dan Implementasi*, Edisi Pert. Yogyakarta: CV BUDI UTAMA, 2024.
- [13] R. J. Hendri Butar-Butar and N. L. Marpaung, "Deep Learning untuk Identifikasi Daun Tanaman Obat Menggunakan Transfer Learning MobileNetV2," *J. Inform. J. Pengemb. IT*, vol. 8, no. 2, pp. 142–148, 2023, doi: 10.30591/jpit.v8i2.5217.
- [14] H. Prayuda, M. R. Rathomi, and N. F. Fahmitra, "Klasifikasi Sampah Laut Jenis Limbah Plastik Menggunakan Metode Convolutional Neural Network Backpropagation (Perairan Kota Tanjungpinang)," *J. Sains dan Inform.*, vol. 11, no. 2, pp. 130–139, 2025, doi: 10.34128/jsi.v11i2.1644.
- [15] E. Oktafanda, "Klasifikasi Citra Kualitas Bibit dalam Meningkatkan Produksi Kelapa Sawit Menggunakan

- Metode Convolutional Neural Network (CNN),” *J. Inform. Ekon. Bisnis*, vol. 4, no. 3, pp. 72–77, 2022, doi: 10.37034/infeb.v4i3.143.
- [16] R. Ardianto and S. K. Wibisono, “Analisis Deep Learning Metode Convolutional Neural Network Dalam Klasifikasi Varietas Gandum,” *J. Kolaboratif Sains*, vol. 6, no. 12, pp. 2081–2092, 2023, doi: 10.56338/jks.v6i12.4938.
- [17] Rexion Alondeo Boimau and Yampi R. Kaesmetan, “Klasifikasi Citra Digital Bumbu dan Rempah Dengan Algoritma Convolutional Neural Network (CNN),” *Repeater Publ. Tek. Inform. dan Jar.*, vol. 2, no. 3, pp. 26–34, 2024, doi: 10.62951/repeater.v2i3.81.
- [18] W. Bismi and M. Qomaruddin, “Klasifikasi Citra Genus panthera Menggunakan Pendekatan Deep learning Berbasis Convolutional Neural network (CNN),” *J. Inform. dan Rekayasa Perangkat Lunak*, vol. 5, no. 2, p. 172, 2023, doi: 10.36499/jinrpl.v5i2.8931.
- [19] H. Chen, G. Zhou, W. He, X. Duan, and H. Jiang, “Classification and identification of agricultural products based on improved MobileNetV2,” *Sci. Rep.*, vol. 14, no. 1, pp. 1–14, 2024, doi: 10.1038/s41598-024-53349-w.
- [20] A. Supit, L. Tompodung, and S. Kumaat, “Mikroplastik sebagai Kontaminan Anyar dan Efek Toksiknya terhadap Kesehatan,” *J. Kesehat.*, vol. 13, no. 1, pp. 199–208, 2022, doi: 10.26630/jk.v13i1.2511.
- [21] V. de Almeida, G. K. Wiecheteck, S. W. Christo, J. E. F. Inglez, A. L. F. Júnior, and G. Staichak, “Microplastic images and Automatic classification by deep learning,” 2025, *Mendeley Data*. doi: 10.17632/yyn2g83vsv.1.