

Rubber Leaf Image Classification Using Artificial Intelligence Methods as an Effort to Improve Plantation Production Results

Klasifikasi Citra Daun Karet dengan Metode Kecerdasan Artifisial sebagai Upaya Peningkatan Hasil Produksi Perkebunan

Irawadi Buyung¹, Evrita Lusiana Utari², Ikhwan Mustiadi³, Sugeng Winardi⁴, Ipan Ariyanto⁵, Latifah Listyalina^{6*}

^{1,2,3,5} Teknik Elektro, Fakultas Sains dan Teknologi, Universitas Respati Yogyakarta, Indonesia

⁴ Sistem Informasi, Fakultas Sains dan Teknologi, Universitas Respati Yogyakarta, Indonesia

⁶ Teknologi Pengolahan Karet dan Plastik, Politeknik ATK Yogyakarta, Indonesia

^{6*} latifah.listyalina@atk.ac.id

*: *Penulis korespondensi (corresponding author)*

Informasi Artikel

Received: December 2020

Revised: January 2021

Accepted: January 2021

Published: February 2021

Menggunakan style info

Abstract

Purpose: Rubber is one of the plantation commodities that contributes positively to the trade surplus in the agricultural sector. Seeing the positive trend in global rubber consumption and production, demand is expected to continue increasing in the future. To enhance rubber productivity, rubber processing technology can be used to make it more efficient, thus increasing the amount of latex extracted from the sap and reducing waste material

Design/methodology/approach: One technology that can be developed to increase the productivity efficiency of rubber plants is by using Artificial Intelligence. This technology is expected to be implemented in the rubber plantation sector, specifically in the automatic recognition of rubber leaves.

Findings/result: The measurement and performance analysis of the rubber leaf image classification algorithm based on Artificial Intelligence has also been evaluated, showing near-perfect accuracy on training data (99.86%) and very good performance on validation data (97.43%), with a very low validation loss (0.0873), indicating that the model has learned well by the last epoch

Originality/value/state of the art: The population in this study consists of image data from various tree leaves, including 10 types of rubber leaves and non-rubber leaves

Keywords: one; two; three
Kata kunci: satu; dua; tiga

Abstrak

Tujuan: Karet merupakan salah satu komoditas perkebunan yang memberikan kontribusi positif pada surplus perdagangan di sektor pertanian. Melihat tren positif dalam konsumsi dan produksi karet global, diperkirakan permintaan akan terus meningkat di masa mendatang. Untuk meningkatkan produktivitas karet, dapat digunakan teknologi pengolahan karet agar lebih efisien, sehingga lateks yang dihasilkan dari getah dapat lebih banyak dan sisa material dapat dikurang.

Perancangan/metode/pendekatan: Salah satu teknologi yang dapat dikembangkan untuk meningkatkan efisiensi produktivitas dari tanaman karet ialah dengan menggunakan Kecerdasan Artifisial. Teknologi tersebut diharapkan dapat diimplementasikan dalam bidang Perkebunan karet, khususnya pada pengenalan daun karet secara otomatis.

Hasil: Pengukuran dan analisis performa algoritma klasifikasi citra daun karet berbasis Kecerdasan Artifisial juga telah diukur, yaitu akurasi model hampir sempurna pada data pelatihan (99.86%) dan sangat baik pada data validasi (97.43%), dengan val_loss sangat rendah (0.0873), menunjukkan bahwa model telah belajar dengan baik, pada epoch terakhir.

Keaslian/ *state of the art*: Populasi pada penelitian ini adalah data citra gambar kumpulan data berbagai daun pohon, terdiri atas 10 jenis daun karet dan daun non karet.

Panjang abstrak maks. 300 kata.

1. Pendahuluan

Karet adalah komoditas perkebunan yang memberikan kontribusi positif pada surplus perdagangan di sektor pertanian. Pada tahun 2019, konsumsi karet alam global mencapai sekitar 13,64 juta ton, sementara konsumsi karet sintetis sekitar 15,16 juta ton. Konsumsi karet alam ini mencakup sekitar 47,35% dari total konsumsi karet (alam dan sintetis). Produksi karet alam dunia pada tahun yang sama mencapai sekitar 13,70 juta ton, dengan 89,44% produksinya berasal dari Asia. Di Indonesia, produksi karet pada tahun 2020 tercatat sebesar 2,88 juta ton, menurun dari 3,30 juta ton pada tahun sebelumnya. Meskipun pasar karet alam lebih kecil dibandingkan dengan karet sintetis, tingkat produksi dan konsumsi karet alam tetap signifikan. Salah satu keunggulan karet alam adalah kestabilan harganya yang tidak dipengaruhi langsung oleh fluktuasi harga minyak dunia, berbeda dengan karet sintetis yang harganya sangat terpengaruh oleh kenaikan harga minyak. Penelitian seperti laporan dari *Association of Natural Rubber Producing Countries (ANRPC)* atau analisis pasar global karet alam oleh *International Rubber Study Group (IRSG)* dapat memberikan data empiris tentang korelasi harga antara karet alam dan sintetis. Dalam 10 tahun terakhir, pangsa pasar karet Indonesia menunjukkan performa yang baik, menjadikan Indonesia produsen karet terbesar kedua di dunia setelah Thailand, dengan daya saing yang kuat di pasar global [1], [2], [3].

Permintaan dan penawaran karet Indonesia relatif stabil dalam beberapa tahun terakhir. Permintaan karet dipengaruhi oleh kebutuhan pasar untuk memproduksi barang jadi dari karet, seperti saat permintaan produk alas kaki atau manufaktur ban meningkat, maka permintaan karet juga akan naik. Di sisi penawaran, jumlah karet yang dapat ditawarkan Indonesia bergantung pada produktivitas dalam negeri. Jika proses dari panen hingga pengolahan karet berjalan lancar, maka Indonesia dapat menyediakan komoditas karet dalam jumlah besar. Melihat tren positif dalam konsumsi dan produksi karet global, diperkirakan permintaan akan terus meningkat di masa mendatang. Sebagai salah satu penghasil utama karet dunia dan basis manufaktur karet, Indonesia memiliki peluang untuk memperluas produksi dengan memanfaatkan lahan perkebunan yang luas. Namun, yang lebih penting adalah meningkatkan teknologi pengolahan karet agar lebih efisien, sehingga lateks yang dihasilkan dari getah dapat lebih banyak dan sisa material dapat dikurangi [4], [5].

Salah satu teknologi yang dapat membantu meningkatkan efisiensi produksi pengolahan karet adalah dengan klasifikasi daun karet menggunakan bantuan kecerdasan artifisial. Hal ini dikarenakan kecerdasan artifisial telah terbukti mampu melakukan berbagai tugas visi komputer seperti klasifikasi citra [6][7][8], deteksi objek[9][10], dan segmentasi citra [11], [12]. Meskipun demikian, klasifikasi citra menggunakan kecerdasan artifisial, khususnya *convolutional neural network* (CNN) bukan merupakan hal yang sederhana. Dalam kasus ini, terdapat beberapa aspek yang perlu dipertimbangkan untuk menghasilkan performa klasifikasi yang memadai, seperti kebutuhan data dalam jumlah besar dan perangkat komputasi dengan spesifikasi yang memadai. Beberapa sumber pustaka atau referensi utama yang relevan dengan penelitian ini adalah sebagai berikut. Penelitian pertama dilakukan oleh [13] yang bertujuan untuk mengklasifikasikan daun, khususnya tanaman herbal yang digunakan dalam pengobatan tradisional. Penelitian ini menggunakan enam jenis daun, yaitu *Barringtonia racemosa*, *Cassia fistula*, *Dipterocarpus grandiflorus*, *Hopea odorata*, *Mimusops elengi*, dan *Pterocarpus indicus*. Setiap jenis daun memiliki 18 citra asli, yang kemudian melalui proses pre-processing menghasilkan 486 citra. Data ini diekstraksi menggunakan metode haar wavelet pada level satu dan level dua, kemudian diklasifikasikan menggunakan model SVM (*Support Vector Machine*) dan KNN (*K-Nearest Neighbor*). Akurasi terbaik pada level satu dan dua adalah 92,80%.

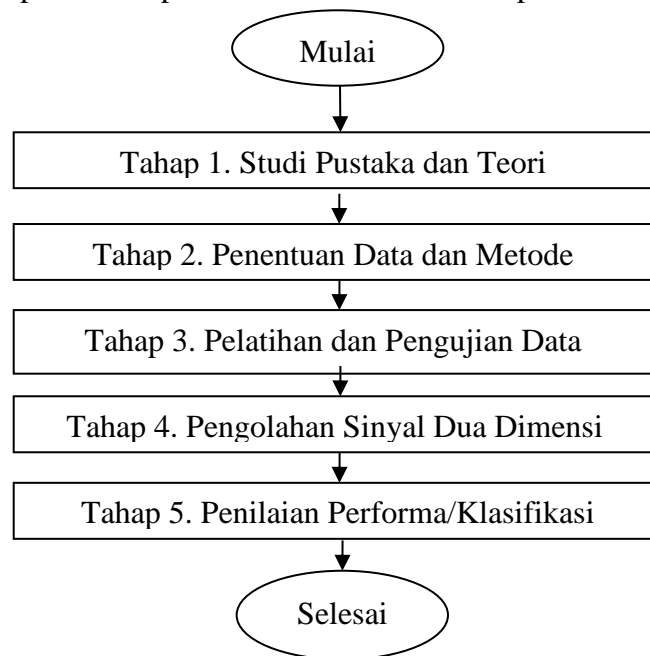
Penelitian lain oleh [14] bertujuan untuk mengklasifikasikan dua jenis daun herbal, yaitu daun katuk (*Sauropus androgynus*) dan daun kelor (*Moringa*), menggunakan metode KNN dan SVM dengan ekstraksi fitur *Fourier Descriptor* (FD) untuk fitur tekstur dan bentuk. Penelitian ini menggunakan 480 citra yang diambil menggunakan kamera smartphone dalam skenario terang dan gelap, dengan pembagian data 80:20 untuk pelatihan dan pengujian. Hasilnya, KNN memperoleh akurasi 92% untuk skenario terang dan 94% untuk skenario gelap, sedangkan SVM mencapai akurasi 96% untuk kedua skenario. Kesimpulannya, metode SVM lebih unggul dalam klasifikasi citra daun herbal dibandingkan KNN.

Penelitian selanjutnya dilakukan oleh [15] yang bertujuan mengklasifikasikan citra daun mangga menggunakan model *Convolutional Neural Network* (CNN). Dataset yang digunakan terdiri dari 1761 citra daun dari tiga jenis mangga, yaitu mangga golek, harum manis, dan manalagi. Model CNN yang digunakan memiliki 4 lapisan konvolusi yang disertai *maxpooling*, dan dilatih selama 60 *epochs* untuk hasil terbaik. Akurasi pelatihan mencapai 97,72%, sementara akurasi validasi mencapai 89,20%. Hasil penelitian ini menunjukkan efektivitas CNN dalam mengklasifikasikan jenis daun berdasarkan karakteristik seperti bentuk, tekstur, dan warna.

Salah satu teknologi yang dapat dikembangkan untuk meningkatkan efisiensi produktivitas dari tanaman karet ialah dengan menggunakan Kecerdasan Artifisial, khususnya model Convolutional Neural Network (CNN). Pada penelitian ini, arsitektur CNN yang digunakan adalah MobileNetV2 [16]. MobileNetV2 adalah arsitektur jaringan saraf convolutional (Convolutional Neural Network) yang dirancang untuk efisiensi komputasi dan performa tinggi pada perangkat dengan keterbatasan sumber daya, seperti perangkat seluler atau embedded systems. Arsitektur ini dipilih sebab memiliki performa klasifikasi yang mumpuni namun tidak membutuhkan memori penyimpanan dan waktu pelatihan yang massif dibandingkan dengan arsitektur lain [17][18]. Teknologi tersebut diharapkan dapat diimplementasikan dalam bidang Perkebunan karet, khususnya pada pengenalan daun karet secara otomatis. Untuk itu, akan dibuat penelitian deteksi daun karet ini.

2. Metode/Perancangan

Penelitian ini berjenis kuantitatif dan menggunakan data sekunder, yakni data citra daun yang bersumber dari situs Kaggle.com. Pengukuran akan dilakukan setelah data-data tersebut selesai dilakukan pengolahan sinyal dua dimensi. Pengukuran yang dilakukan berupa pengukuran performa pengolahan sinyal dan akan dianalisis hasil pengukuran tersebut. Populasi pada penelitian ini adalah data citra gambar kumpulan data berbagai daun pohon, terdiri atas 10 jenis daun karet dan daun non karet. Data yang digunakan berupa data citra Apta (*Bauhinia Racemosa*), Vad (*Ficus Benghalensis*), Pohon Karet (*Ficus Elastica Roxb*), Karanj (*Pongamia Pinnata*), Kashid (*Senna Siamea*), Sita Ashok (*Saraca Asoka*), Pimpal (*Ficus Religiosa*), Nilgiri (*Globulus Kayu Putih*), Sonmohar (*Peltophorum Pterocarpum*), Villayati Chinch (*Pithecellobium Dulce*). Jenis-jenis data tersebut dipilih karena ketersediaan database sekunder. Klasifikasi yang dilakukan menjadi dua kelas (*binary classification*), yaitu kelas daun karet dan daun non karet di mana data daun non karet berisi daun selain Pohon Karet (*Ficus Elastica Roxb*). Adapun tahapan dalam penelitian ini diilustrasikan pada Gambar di bawah ini, yaitu



Gambar 1. Bagan Alur Penelitian

Adapun tahapan-tahapan penelitian pada Gambar dapat dijelaskan sebagai berikut:

- Tahap pertama dilakukan dengan peninjauan teori dan pustaka yang terkait dengan penelitian ini. Teori yang dimaksud ialah dasar-dasar teori yang terkait pada penelitian ini, seperti hal-hal terkait karet, daun karet, dan Kecerdasan Artifisial sedangkan pustaka yang dimaksud adalah beberapa penelitian terdahulu yang terkait dengan penelitian ini di mana akan menjadi masukan dan dasar dalam melakukan penelitian ini.
- Tahap kedua adalah tahapan dalam menentukan data dan metode penelitian. Penentuan ini disesuaikan dengan judul yang telah diusung, seperti data yang dibutuhkan ialah data yang sudah diklasifikasikan menurut kebutuhan penelitian ini di mana data tersebut tersedia dalam dataset sekunder Kaggle.com. Untuk metode penelitian, akan digunakan metode Kecerdasan Artifisial, khususnya *convolutional neural network* (CNN) yang mampu mengidentifikasi kelas yang dibutuhkan. Model CNN yang digunakan adalah MobileNetV2 [16]. Model ini dipilih karena arsitekturnya yang ringan, namun memiliki kemampuan klasifikasi yang tinggi.
- Tahap ketiga dan tahap keempat ialah mengaplikasikan metode Kecerdasan Artifisial yang telah dipilih dari hasil tahap sebelumnya. Keberhasilan pelatihan metode akan menentukan keberhasilan pengujian yang akan digunakan. Hal tersebut akan bergantung pada koefisien-koefisien yang akan dipilih pada proses pelatihan.

Setelah proses pengujian selesai, tahap kelima merupakan prosesn penilaian performa hasil pengujian sebelumnya. Hasil kuantitatif tahapan ini menentukan keberhasilan penelitian ini. Baik tidaknya nilai performa penelitian akan menentukan proses publikasi yang ada pada tahap keenam.

3. Hasil dan Pembahasan

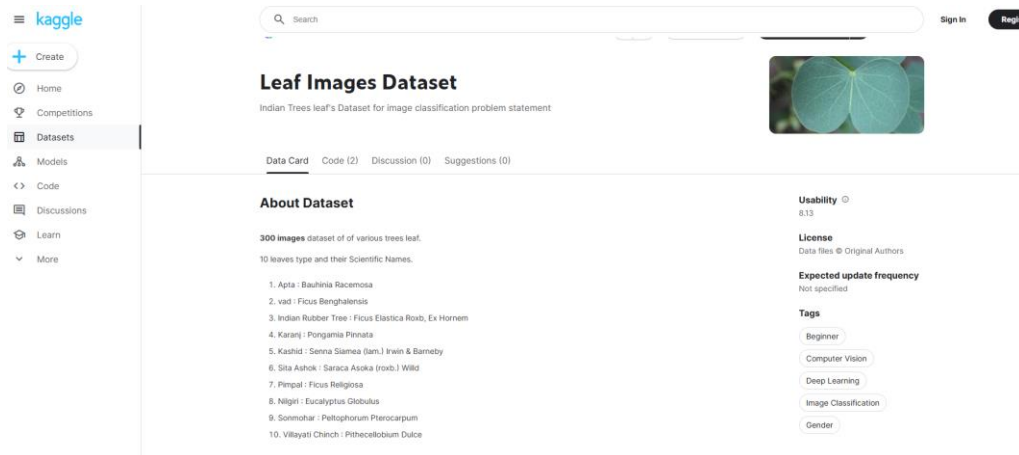
Telah dilakukan tahap 1, 2, dan sebagainya tahap 3 pada penelitian mengenai deteksi citra daun karet yang adapapun capaiannya sebagai berikut.

1. Tahap 1: Studi Pustaka

Peneliti telah melakukan studi terkait penelitian ini seperti macam-macam daun yang dapat dideteksi sesuai penelitian terdahulu dan jenis kecerdasan artifisial yang akan digunakan pada penelitian ini. Berdasarkan studi pustaka yang dilakukan, metode kecerdasan artifisial yang digunakan di penelitian ini adalah CNN.


2. Akuisisi Data

Penentuan data juga telah dilakukan pada penelitian ini, yaitu dengan menggunakan data sekunder dari situs kaggle. Situs tersebut mempunyai banyak dataset di mana yang membahas mengenai penelitian itu ada pada <https://www.kaggle.com/datasets/ichhadhari/leaf-images/data>. Berikut tampilan data sekunder yang digunakan.



Gambar 1. Tampilan Dataset

1. Dari tampilan tersebut, terdapat 10 kelas jenis daun di mana satu jenis daun merupakan daun karet. Pada setiap kelas data, terdapat kurang lebih 300 gambar sehingga total keseluruhan data yang akan digunakan dari 10 kelas ialah 3000 gambar. Nantinya gambar-gambar tersebut akan dibagi menjadi data pelatihan dan data pengujian dengan presentase kurang lebih 70:30, yaitu 2100 gambar pelatihan dan 900 gambar pengujian yang akan dibagi sama rata pada setiap kategori gambar.
2. Telah dilakukan penyimpanan keseluruhan data penelitian, yaitu dengan mengunduh keseluruhan data. Kemudian dilakukan pembagian folder pelatihan dan pengujian menurut kriteria yang telah dijelaskan sebelumnya. Hal tersebut akan mempermudah pemanggilan data pada proses pelatihan dan pengujian. Berikut contoh gambar dari masing-masing kategori yang ada pada penelitian ini.



Gambar 2. Contoh Gambar pada Setiap Kategori

- (a) Apta : Bauhinia Racemosa (b) Indian Rubber Tree : Ficus Elastica Roxb, Ex Hornem
(b) Karanj : Pongamia Pinnata (d) Kashid : Senna Siamea (lam.) Irwin & Barneby
(e) Nilgiri : Eucalyptus Globulus (f) Pimpal : Ficus Religiosa (g) Sita Ashok : Saraca

Asoka (roxb.) Willd (h) Sonmohar : Peltophorum Pterocarpum (i) vad : Ficus Benghalensis
(j) Villayati Chinch : Pithecellobium Dulce

3. Tahap 3: Pelatihan dan Pengujian

Tahap selanjutnya setelah akuisisi data adalah implementasi metode kecerdasan artifisial berbasis jaringan saraf konvolusional (CNN) guna klasifikasi citra daun karet. Pada penelitian ini, arsitektur CNN yang digunakan adalah MobileNetV2. Tahap klasifikasi citra daun karet dengan MobileNetV2 diawali dengan pembuatan *class* generator melalui bahasa pemrograman Python yang dilakukan sebagai berikut.

```
import tensorflow as tf
import pathlib
import os
import matplotlib.pyplot as plt
import pandas as pd
import numpy as np

# Define directories for training and validation data
train_dir = "/content/drive/MyDrive/penelitian daun/pelatihan"
validation_dir = "/content/drive/MyDrive/penelitian daun/pengujian"

# Define parameters for data loading
BATCH_SIZE = 32
IMG_SIZE = (224, 224)

# Load training dataset
train_dataset = tf.keras.utils.image_dataset_from_directory(
    train_dir,
    shuffle=True,
    batch_size=BATCH_SIZE,
    image_size=IMG_SIZE
)

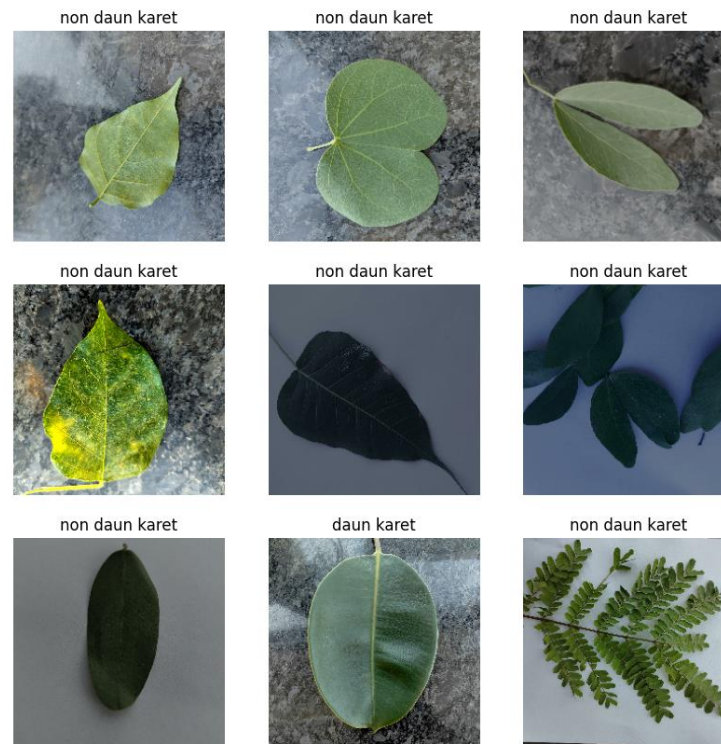
# Load validation dataset
validation_dataset = tf.keras.utils.image_dataset_from_directory(
    validation_dir,
    shuffle=True,
    batch_size=BATCH_SIZE,
    image_size=IMG_SIZE
)

class_names = train_dataset.class_names

# Optimize dataset performance with prefetching
AUTOTUNE = tf.data.AUTOTUNE
train_dataset = train_dataset.prefetch(buffer_size=AUTOTUNE)
validation_dataset = validation_dataset.prefetch(buffer_size=AUTOTUNE)

# Visualize a few images and labels from the dataset
plt.figure(figsize=(10, 10))
for images, labels in train_dataset.take(1):
    for i in range(9):
        ax = plt.subplot(3, 3, i + 1)
        plt.imshow(images[i].numpy().astype("uint8"))
        plt.title(class_names[labels[i]])
        plt.axis("off")
plt.show()
```

Langkah visualisasi sederhana disertakan untuk menampilkan beberapa gambar dari dataset pelatihan beserta labelnya sebagai berikut.

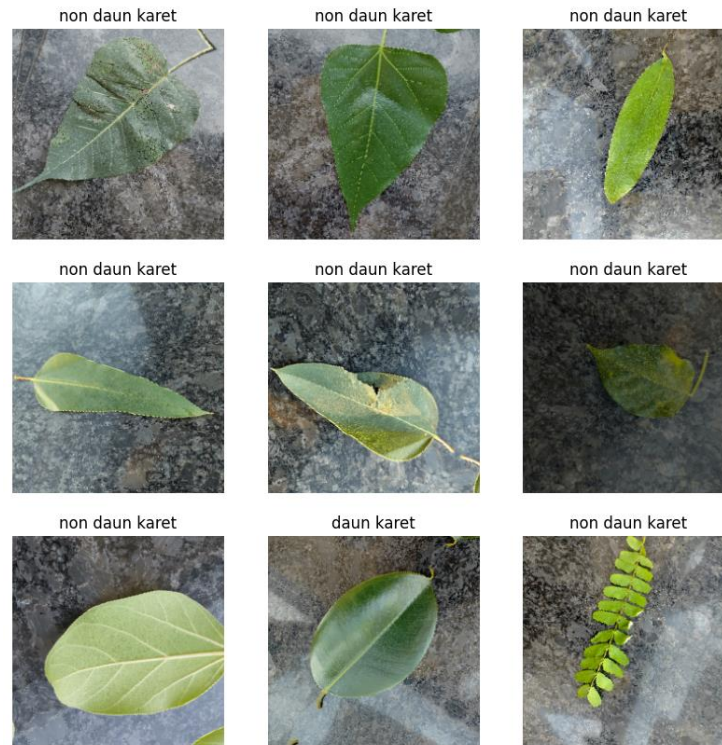


Gambar 3. Contoh hasil pemuatan dataset

Data yang sudah dimuat di atas pada dasarnya dapat digunakan untuk melakukan pelatihan MobileNetV2. Namun, ada kalanya jumlah data yang terbatas dapat mengakibatkan *overfitting*, yakni performa MobileNetV2 pada data pengujian jauh lebih rendah dari performa pada data pelatihan. Oleh karenanya, digunakan konsep augmentasi data melalui sejumlah transformasi gambar acak yang memuat rotasi dan pencerminan untuk memperkaya variasi data pelatihan yang ada. Tahap augmentasi data diimplementasikan dengan Langkah sebagai berikut.

1. Definisikan operasi Augmentasi Data:
 - `RandomFlip('horizontal')`: Membalikkan gambar secara horizontal secara acak.
 - `RandomRotation(0.2)`: Memutar gambar secara acak hingga 20 derajat.
2. Pra-pemrosesan Input: Fungsi ini spesifik untuk MobileNetV2 dan mengatur nilai piksel input ke rentang yang diharapkan oleh model.
3. Visualisasi: Fungsi `visualize_augmentation` mengambil satu batch gambar dari dataset dan menerapkan augmentasi data. Kemudian menampilkan beberapa gambar yang telah diaugmentasi menggunakan Matplotlib.

Contoh hasil citra teraugmentasi adalah sebagai berikut.



Gambar 4. Contoh hasil tahap augmentasi data

Setelah data pelatihan dan pengujian dimuat, tahap selanjutnya adalah pendefinisian model MobileNetV2 yang akan digunakan. Tahap ini dilaksanakan melalui beberapa langkah di bawah ini.

1. Pembuatan Model Dasar dengan MobileNetV2:

```
IMG_SHAPE = IMG_SIZE + (3,)
base_model = tf.keras.applications.MobileNetV2(input_shape=IMG_SHAPE,
                                               include_top=False,
                                               weights='imagenet')
```

- **IMG_SHAPE**: menentukan bentuk dari gambar input, yaitu (224, 224, 3). Ini menunjukkan tinggi, lebar, dan jumlah saluran warna (RGB).
- **base_model**: merupakan instance dari model MobileNetV2 yang telah dilatih sebelumnya pada dataset ImageNet. Dengan mengatur `include_top=False`, lapisan *fully connected* di bagian atas jaringan (yang digunakan untuk klasifikasi di ImageNet) dihilangkan. Ini memungkinkan model digunakan sebagai ekstraktor fitur, memberikan fleksibilitas untuk menambahkan lapisan klasifikasi khusus.

2. Global Average Pooling dan Lapisan Prediksi

```
global_average_layer = tf.keras.layers.GlobalAveragePooling2D()
prediction_layer = tf.keras.layers.Dense(1, activation='sigmoid')
```

- **global_average_layer**: Lapisan ini mengurangi dimensi spasial dari peta fitur yang dihasilkan oleh model dasar dengan menghitung rata-rata setiap peta fitur. Ini mengonversi peta fitur 2D menjadi vektor fitur 1D tunggal per gambar, yang membantu mengurangi parameter model dan mengurangi *overfitting*.
- **prediction_layer**: Lapisan Dense dengan satu neuron dan fungsi aktivasi sigmoid, cocok untuk tugas klasifikasi biner. Outputnya akan berupa skor probabilitas antara 0

dan 1, menunjukkan kemungkinan input termasuk dalam kelas positif.

3. Membangun Model

```
inputs = tf.keras.Input(shape=(224, 224, 3))
x = data_augmentation(inputs)
x = preprocess_input(x)
x = base_model(x, training=True)
x = global_average_layer(x)
x = tf.keras.layers.Dropout(0.2)(x)
outputs = prediction_layer(x)
model = tf.keras.Model(inputs, outputs)
```

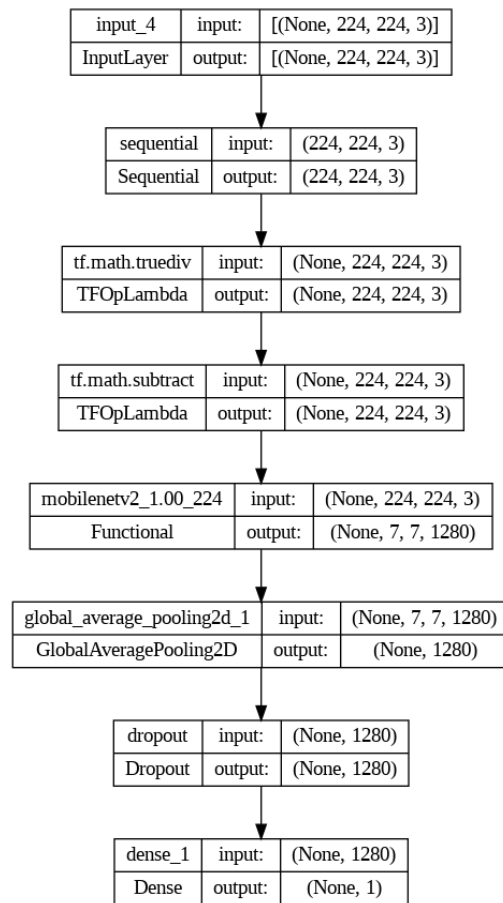
- *inputs*: Mendefinisikan tensor input untuk model dengan bentuk (224, 224, 3).
- *data_augmentation*: Menerapkan augmentasi data pada input, termasuk transformasi seperti *flipping* dan rotasi, membantu model untuk generalisasi yang lebih baik.
- *preprocess_input*: Melakukan pra-pemrosesan data sesuai kebutuhan MobileNetV2, seperti penskalaan nilai piksel.
- *base_model(x, training=False)*: Model dasar mengekstraksi fitur dari gambar input. Mengatur `training=True` memastikan bahwa model dasar berjalan dalam mode pelatihan.
- *Dropout*: Menambahkan lapisan *Dropout* dengan tingkat 0.2 untuk secara acak menghilangkan 20% unit selama pelatihan, yang membantu mencegah *overfitting*.
- *model*: Menggabungkan semua lapisan menjadi model lengkap, dengan `inputs` sebagai input dan `outputs` sebagai output akhir.

4. Mengompilasi Model

```
base_learning_rate = 0.0001
model.compile(optimizer=tf.keras.optimizers.Adam(learning_rate=base_learning_rate),
              loss=tf.keras.losses.BinaryCrossentropy(),
              metrics=[tf.keras.metrics.BinaryAccuracy(threshold=0.5,
              name='accuracy')])
```

- *base_learning_rate*: Mengatur laju pembelajaran awal untuk *optimizer*. Laju pembelajaran yang lebih kecil sering digunakan saat melakukan fine-tuning model yang telah dilatih sebelumnya.
- *Adam optimizer*: Algoritma optimasi laju pembelajaran adaptif yang menyesuaikan laju pembelajaran untuk setiap parameter, membuatnya efisien dan banyak digunakan.
- *BinaryCrossentropy*: Fungsi *loss* yang digunakan untuk klasifikasi biner, yang mengukur perbedaan antara probabilitas prediksi dan label sebenarnya.
- *BinaryAccuracy*: Metrik untuk memantau selama pelatihan dan evaluasi, mengukur akurasi prediksi model berdasarkan ambang batas 0.5.

Hasil dari menjalankan kode di atas adalah didapatkannya model yang akan dilatih dengan struktur sebagai berikut.



Gambar 5. Struktur Model yang Diusung

Model di atas bekerja dengan cara:

1. Menerima gambar input.
2. Mengekstrak fitur-fitur penting melalui lapisan konvolusi dan *pooling*.
3. Mengurangi dimensi fitur menggunakan *global average pooling*.
4. Melakukan klasifikasi menggunakan lapisan *dense*

Model ini cocok untuk tugas klasifikasi biner, yaitu mengklasifikasikan gambar ke dalam dua kelas. Setelah didapatkan struktur modelnya, kemudian dilakukan proses pelatihan dan pengujian. Secara keseluruhan, program ini melatih model, mencatat akurasi dan *loss* selama pelatihan serta validasi, dan kemudian menampilkan grafik untuk membandingkan akurasi serta *loss* antara pelatihan dan validasi selama beberapa *epoch*. Program ini melatih model machine learning dengan data latih (*train_dataset*) selama 10 *epoch* awal (*initial_epochs*). Kemudian, program mengevaluasi performa model menggunakan data validasi (*validation_data*). *Listing program* yang dibuat memberikan keluaran (*output*) dari proses pelatihan model pembelajaran mesin (seperti jaringan saraf) dalam beberapa *epoch*, yaitu sebagai berikut.

Epoch	Time per step	Accuracy	Loss	Val Accuracy	Val Loss
Epoch 1/10	1931s 32s/step	0.8061	0.3793	0.3307	1.8929
Epoch 2/10	207s 3s/step	0.9939	0.0298	0.6547	0.8192
Epoch 3/10	202s 3s/step	0.9952	0.0176	0.6492	0.8633
Epoch 4/10	143s 2s/step	0.9980	0.0098	0.5698	1.2167
Epoch 5/10	232s 3s/step	0.9930	0.0268	0.9654	0.1266
Epoch 6/10	167s 2s/step	0.9946	0.0141	0.8838	0.3220
Epoch 7/10	130s 2s/step	0.9980	0.0062	0.9117	0.2313
Epoch 8/10	135s 2s/step	1.0000	0.0035	0.9430	0.1780
Epoch 9/10	136s 2s/step	0.9972	0.0062	0.9777	0.0957
Epoch 10/10	180s 3s/step	0.9986	0.0047	0.9743	0.0873

Gambar 6. Hasil Validasi

Berikut penjelasan dari hasilnya:

1. *Epoch*: Setiap *epoch* adalah satu siklus penuh di mana model dipelajari dari seluruh data pelatihan sekali. Dalam contoh ini, pelatihan dilakukan selama 10 *epoch*.
 2. *Accuracy* (Akurasi): Menunjukkan seberapa baik model dapat memprediksi dengan benar label dari data pelatihan. Akurasi mendekati 1,0 berarti model memiliki performa yang sangat baik.
 - o Pada *epoch* pertama, akurasi sebesar 0.8061 (80.61%), artinya pada permulaan model telah bisa memprediksi dengan cukup baik.
 - o Akurasi terus meningkat seiring *epoch*, hingga di *epoch* ke-10 mencapai 0.9986 (99.86%).
 3. *Loss* (Kerugian): Menunjukkan seberapa baik model belajar, diukur dengan fungsi kerugian yang digunakan. Semakin rendah nilai loss, semakin baik model belajar.
 - o Pada *epoch* pertama, loss berada di 0.3793 dan terus menurun hingga pada *epoch* terakhir hanya 0.0047.
 4. *Val_accuracy* (Akurasi Validasi): Ini menunjukkan akurasi model pada data validasi (data yang tidak dilatih), digunakan untuk mengevaluasi generalisasi model.
 - o Pada *epoch* pertama, *val_accuracy* sangat rendah yaitu 0.3307 (33.07%), menunjukkan bahwa pada awalnya model kesulitan dalam generalisasi.
 - o *Val_accuracy* meningkat drastis di *epoch* 5 dengan nilai 0.9654 (96.54%) dan stabil mendekati angka 1.0 pada epoch akhir.
 5. *Val_loss* (Kerugian Validasi): Sama seperti loss, tetapi ini diukur pada data validasi. Idealnya, *val_loss* harus menurun seiring waktu, yang berarti model tidak hanya belajar dari data pelatihan, tetapi juga bisa generalisasi dengan baik.
 - o Pada awalnya, *val_loss* sangat tinggi (1.8929) di epoch pertama, tetapi terus menurun hingga mencapai 0.0873 di *epoch* terakhir.
 6. *Time per step*: Setiap *epoch* memerlukan sejumlah waktu untuk menyelesaikan satu langkah pelatihan. Ini ditunjukkan oleh angka seperti "32s/step" pada *epoch* pertama dan "3s/step" pada *epoch* lainnya.
- Ringkasan
 - Pada awalnya, model memiliki akurasi pelatihan yang cukup tinggi (80%) tetapi akurasi validasinya sangat rendah (33%), menunjukkan bahwa model mungkin mengalami *overfitting*.

- Seiring dengan pelatihan lebih lanjut, model menjadi lebih baik dalam hal validasi, dengan *val_accuracy* meningkat secara signifikan dan *val_loss* menurun.
- Pada *epoch* terakhir, akurasi model hampir sempurna pada data pelatihan (99.86%) dan sangat baik pada data validasi (97.43%), dengan *val_loss* sangat rendah (0.0873), menunjukkan bahwa model telah belajar dengan baik.

Terakhir, program membuat visualisasi berupa grafik untuk melihat bagaimana akurasi dan loss berubah selama proses pelatihan.



Gambar 7. Grafik Akurasi Pelatihan dan Validasi

Grafik di atas menunjukkan perbandingan akurasi antara data pelatihan (*training accuracy*) dan data validasi (*validation accuracy*) selama proses pelatihan model *machine learning* dengan detail sebagai berikut.

Sumbu X:

- *Epoch*: Menunjukkan jumlah iterasi pelatihan yang telah dilakukan. Setiap *epoch*, model akan mempelajari seluruh dataset pelatihan sekali.

Sumbu Y:

- *Accuracy*: Menunjukkan tingkat akurasi model dalam memprediksi label yang benar. Nilai akurasi berkisar antara 0 hingga 1, di mana nilai 1 berarti model memprediksi semua data dengan benar.

Dua Garis:


- *Training Accuracy*: Garis biru menunjukkan akurasi model pada data pelatihan.
- *Validation Accuracy*: Garis oranye menunjukkan akurasi model pada data validasi. Data validasi adalah bagian dari data yang tidak digunakan untuk pelatihan, sehingga digunakan untuk mengukur kemampuan generalisasi model.

Interpretasi:

- **Awal Pelatihan**: Pada awal pelatihan, akurasi model pada kedua data (pelatihan dan validasi) cenderung rendah. Ini karena model belum "belajar" cukup banyak tentang data.
- **Peningkatan Akurasi**: Seiring bertambahnya *epoch*, akurasi model pada kedua data umumnya meningkat. Ini menunjukkan bahwa model semakin baik dalam mempelajari pola dalam data.

- *Overfitting*: Terlihat bahwa pada beberapa *epoch* terakhir, akurasi pada data pelatihan terus meningkat, sedangkan akurasi pada data validasi mulai stagnan atau bahkan menurun. Ini adalah indikasi terjadinya *overfitting*. *Overfitting* terjadi ketika model terlalu menghafal data pelatihan sehingga tidak dapat menggeneralisasi dengan baik pada data baru (data validasi).


Grafik ini menunjukkan bahwa model telah berhasil belajar dari data pelatihan, tetapi terdapat indikasi *overfitting*. Secara singkat, grafik ini memberikan gambaran tentang bagaimana model *machine learning* belajar dari waktu ke waktu dan bagaimana kita dapat mengidentifikasi masalah seperti *overfitting*.



Grafik 8. Grafik Kerugian Pelatihan dan Validasi

Grafik ini menunjukkan perbandingan antara loss pada data pelatihan (*training loss*) dan data validasi (*validation loss*) selama proses pelatihan model *machine learning*. Grafik ini menunjukkan bahwa model telah berhasil belajar dari data pelatihan, tetapi terdapat indikasi *overfitting*. *Overfitting* adalah masalah yang umum terjadi dalam *machine learning* dan dapat menurunkan kinerja model pada data yang belum pernah dilihat sebelumnya. Secara singkat, grafik ini memberikan gambaran tentang bagaimana model *machine learning* belajar dari waktu ke waktu dan bagaimana kita dapat mengidentifikasi masalah seperti *overfitting*.

Selanjutnya, digunakan *confusion matrix* (matriks kebingungan) sebagai evaluasi performa model pada validasi dataset. *Confusion Matrix* adalah sebuah tabel yang digunakan untuk mengevaluasi performa model klasifikasi. Tabel ini memberikan gambaran rinci mengenai seberapa baik model dapat membedakan antara kelas-kelas yang berbeda. Matriks kebingungan akan menunjukkan berapa banyak prediksi yang benar dan salah untuk setiap kelas (*Class 0* dan *Class 1*). Hal tersebut membantu memahami kualitas model dalam hal klasifikasi yang benar dan kesalahan yang dibuat model.



Gambar 9. Confusion Matrix

Dari matriks di atas, dapat disimpulkan bahwa model klasifikasi ini memiliki performa yang cukup baik dalam membedakan antara kelas 0 dan kelas 1. Jumlah data yang diklasifikasikan dengan benar jauh lebih banyak dibandingkan dengan yang salah dengan detail sebagai berikut.

- Model ini cenderung sangat baik dalam mengklasifikasikan data ke dalam kelas 1.
- Model ini masih memiliki sedikit kesulitan dalam mengklasifikasikan data ke dalam kelas 0, terutama dalam hal *false positive*.

4. Kesimpulan dan Saran

Pengimplementasian Kecerdasan Artifisial sebagai media pengklasifikasian citra daun karet otomatis telah dilakukan dengan menrancang algoritma. Pengukuran dan analisis performa algoritma klasifikasi citra daun karet berbasis Kecerdasan Artifisial juga telah diukur, yaitu akurasi model hampir sempurna pada data pelatihan (99.86%) dan sangat baik pada data validasi (97.43%), dengan *val_loss* sangat rendah (0.0873), menunjukkan bahwa model telah belajar dengan baik, pada epoch terakhir.

Daftar Pustaka

- [1] L. F. Syarif, D. S. Agustina, A. Alamsyah, I. S. Nugraha, H. Asywadi, and S. Selatan, "OUTLOOK KOMODITAS KARET ALAM INDONESIA 2023 Commodity Outlook of Indonesian Natural Rubber 2023 Pusat Penelitian Karet . Jl . Raya Palembang – Pk . Balai Km . 29 , Sembawa , Email : lina_fsy@yahoo.com," vol. 41, no. September, pp. 47–58, 2023.
- [2] N. H. P. Harahap and B. A. Segoro, "Analisis Daya Saing Komoditas Karet Alam Indonesia ke Pasar Global," *Jurnal Transborders*, vol. 1, no. 2, pp. 130–143, 2018.
- [3] B. S. Sembiring, Y. Syaukat, and Hastuti, "Struktur Pasar Dan Daya Saing Karet Alam Indonesia Di Amerika Serikat," *Buletin Ilmiah Litbang Perdagangan*, vol. 15, no. 2, pp. 235–256, 2021, doi: 10.30908/bilp.v15i2.623.
- [4] S. H. Sahir, "Prospek Transaksi Komoditas Karet Indonesia Sesudah Pandemi Covid 19: Kajian Pustaka," *Warta Perkaretan*, vol. 40, no. 1, pp. 1–14, 2021.

- [5] H. Dewi Purnomowati, S. Widodo, S. Hartono, and D. Hadi Darwanto, "Analisis Permintaan Karet Alam Indonesia di Pasar Internasional," *AGRARIS: Journal of Agribusiness and Rural Development Research*, vol. 1, no. 2, pp. 136–148, 2015, doi: 10.18196/agr.1217.
- [6] 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.
- [7] 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.
- [8] 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. doi: 10.1109/ICSITech46713.2019.8987485.
- [9] 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, [Online]. Available: <http://arxiv.org/abs/1506.02640>
- [10] T.-Y. Lin, P. Goyal, R. Girshick, K. He, and P. Dollár, "Focal Loss for Dense Object Detection," *IEEE Trans Pattern Anal Mach Intell*, vol. 42, no. 2, pp. 318–327, 2020, doi: 10.1109/TPAMI.2018.2858826.
- [11] 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.
- [12] 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.
- [13] A. A. Kusumaning. Putri, "Sistem Klasifikasi Jenis Daun Berdasarkan Tekstur Menggunakan Algoritma Transformasi Haar Wavelet Dan Machine Learning," 2022.
- [14] P. R. Prayoga, P. Purnawansyah, T. Hasanuddin, and H. Darwis, "No Title Klasifikasi Daun Herbal Menggunakan K-Nearest Neighbor dan Support Vector Machine dengan Fitur Fourier Descriptor," *Edumatic: Jurnal Pendidikan Informatika*, vol. 7, no. 1, pp. 160–168, 2023.
- [15] F. Fitriyaningsih and R. Rodiah, "KLASIFIKASI JENIS CITRA DAUN MANGGA MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK," *Jurnal Ilmiah Teknologi dan Rekayasa*, vol. 25, no. 3, 2020.
- [16] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, "MobileNetV2: Inverted Residuals and Linear Bottlenecks," in *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2018, pp. 4510–4520. doi: 10.1109/CVPR.2018.00474.
- [17] I. Buyung, A. Q. Munir, N. W. S., and L. Listyalina, "Identifying Types of Waste as Efforts in Plastic Waste Management Based on Deep Learning," *Telematika: Jurnal Informatika dan Teknologi Informasi*, vol. 20, no. 3, pp. 362–372, 2023.
- [18] L. et al Listyalina, "Deep-RIC: Plastic Waste Classification using Deep Learning and Resin Identification Codes (RIC).," *Telematika : Jurnal Informatika dan Teknologi Informasi*, vol. 19, no. 2, pp. 215–228, 2022.