

Identifikasi Objek *Fragile* dan *Non-Fragile* untuk Pengelompokan Secara Otomatis Menggunakan CNN

Charles Jason^{1)*}, Rino²⁾, Edy³⁾

¹⁾²⁾³⁾ Universitas Buddhi Dharma

Jl. Imam Bonjol No.41, Tangerang, Indonesia

¹⁾charlesjason2233@gmail.com

²⁾rino@ubd.ac.id

³⁾edy.edy@ubd.ac.id

Article history:

Received 07 Nov 2024;
Revised 14 Nov 2024;
Accepted 02 Des 2024;
Available online 27 Des 2024

Keywords:

Bidang Pengiriman
InceptionV3
Klasifikasi Gambar
Machine Learning
Metode SDLC

Abstrak

Pada masa perkembangan teknologi ini, penggunaan *marketplace* dalam transaksi jual beli semakin pesat di Indonesia, permasalahan yang muncul pada kegiatan jual beli secara *online* ini adalah adanya pihak ketiga diantara pembeli dan penjual, yaitu bidang pengiriman. Disaat pembeli membeli barang melalui *marketplace*, penjual harus mengirim barang tersebut sebelum dapat dengan langsung diterima oleh pembeli, seperti halnya transaksi jual beli tradisional. Hal ini membuat timbulnya resiko kerusakan barang pada saat pengiriman akibat kelalaian pada pihak pengirim disaat mengelompokkan barang *fragile* dan *non-fragile*. Dari masalah modern ini, dibutuhkan solusi modern yang dapat mengelompokkan barang *fragile* dan *non-fragile* secara otomatis, penelitian ini menawarkan solusi terhadap masalah tersebut melalui implementasi model CNN dengan arsitektur *InceptionV3*. Arsitektur ini memiliki keunggulan dalam meminimalkan jumlah operasi dan tetap mempertahankan akurasi tinggi. penelitian ini bertujuan untuk menghindari potensi skenario kerusakan selama proses pengiriman, dengan cara mendeteksi sebelum pengiriman barang yang akan dikirim, apakah barang tersebut termasuk kedalam kategori *fragile* atau *non-fragile*. Penelitian ini menggunakan *dataset visual* berupa gambar objek yang tersedia secara *online* dalam pembuatan model, dan menggunakan metode SDLC pada perancangan *website* untuk memastikan sistem yang dibangun dapat memiliki kualitas tinggi serta sesuai dengan tujuan utamanya. Hasil penelitian berupa sistem yang dapat melakukan klasifikasi objek *fragile* dan *non-fragile* secara otomatis melalui gambar dengan akurasi rata-rata 90%. Dengan akurasi tersebut, hasil dari penelitian ini diharapkan dapat menjadi solusi alternatif pada pengelompokan barang di bidang pengiriman. Penelitian ini juga membuka penelitian kedepannya untuk dapat mengoptimasi model dan menambah model arsitektur yang digunakan, guna memberikan hasil klasifikasi yang lebih akurat.

I. PENDAHULUAN

Era teknologi dan digital telah membawa perubahan besar dalam kehidupan, terutama bagi generasi muda yang akrab dengan kemajuan pesat ini. Dalam lingkungan bisnis, perkembangan teknologi menciptakan persaingan ketat, di mana perusahaan, baik lokal maupun internasional, harus beradaptasi untuk meraih keunggulan kompetitif [1].

Di bidang pengiriman, teknologi telah banyak diadopsi untuk membantu operasional dan memberikan berbagai keunggulan, seperti mempercepat proses pengiriman, meningkatkan ketepatan waktu, dan menekan biaya. Penggunaan teknologi ini, mulai dari sistem pelacakan berbasis GPS hingga otomatisasi manajemen inventaris dan penyimpanan, memungkinkan perusahaan meningkatkan efisiensi dalam performa pengiriman mereka secara signifikan [2].

Meskipun telah banyak diterapkan, masalah seperti kerusakan barang selama proses pengiriman masih sering terjadi dan menjadi tantangan besar. Hal ini bisa disebabkan oleh berbagai faktor, namun penyebab utama dari masalah ini merupakan adanya kesalahan pada pengelompokan barang *fragile* dan *non-fragile*. Maka dari itu,

* Corresponding author

perusahaan di bidang pengiriman perlu terus berinovasi dan mencari solusi agar teknologi yang dipakai dalam pembuatan tidak hanya meningkatkan efisiensi, dan diharapkan mampu meminimalisir risiko kerusakan pada barang, sehingga kualitas layanan yang diberikan kepada pelanggan tetap terjaga [3].

Beberapa hal yang perusahaan dapat lakukan merupakan menggunakan *machine learning*. Dimana perusahaan memanfaatkan Sistem yang mampu belajar membuat keputusan secara mandiri tanpa perlu diprogram berulang kali oleh manusia, sehingga komputer dapat semakin pintar dan mampu belajar dari pengalaman melalui data yang diperolehnya. Hal ini didasarkan pada teknik pembelajaran yang digunakan [4].

Dengan menggunakan *machine learning*, perusahaan dapat membuat sistem otomatis yang dapat memberikan keunggulan pada jaman perkembangan teknologi pada saat ini [5]. Sistem klasifikasi seperti pada penelitian ini, dapat melakukan identifikasi objek secara otomatis, hal ini diharapkan dapat menjadi solusi alternatif dalam masalah yang dihadapi pada bidang pengiriman pada saat ini [6].

Sistem yang dikembangkan menggunakan model *InceptionV3*, dan merupakan model yang memiliki *layer* mencapai 48 *layer*. *InceptionV3* beroperasi secara terstruktur untuk mengorganisasi objek, di mana hasil dari satu proses konvolusi digunakan sebagai input untuk proses konvolusi berikutnya [7]. Dibanding arsitektur model lain, *InceptionV3* memiliki keunggulan dalam menangani gambar dengan variabilitas tinggi, seperti sudut pencahayaan, warna, dan bentuk objek. Dalam kasus *fragile* dan *non-fragile*, model dapat mengenali objek dengan berbagai atribut fisik tanpa kehilangan akurasi, dikarenakan banyaknya variasi dari objek gambar, membuat *inceptionV3* lebih unggul dibandingkan model arsitektur lain seperti *ResNet* dan lebih memberikan efisiensi komputasi untuk klasifikasi sederhana seperti klasifikasi gambar untuk 2 label, sesuai dengan yang dibutuhkan pada penelitian ini.

Untuk dapat membuat sistem identifikasi barang otomatis, peneliti menggunakan *machine learning* dan memanfaatkan model *InceptionV3*, dengan tujuan untuk melakukan identifikasi barang dalam bentuk gambar, dan memberikan label *fragile* atau *non-fragile*.

II. TINJAUAN PUSTAKA

Penelitian Mohammed Arif Iftakher Mahmood, Nasrin Aktar, Md. Fazlul Kader (2020), dengan judul “*A hybrid approach for diagnosing diabetic retinopathy from fundus image exploiting deep features*” menggunakan *InceptionV3*. Dengan tujuan mendeteksi penyakit diabetes retinopathy menggunakan kapasitas gambar dalam skala yang besar, dan menghasilkan sistem deteksi menggunakan gambar dengan memanfaatkan model *InceptionV*. Pemrosesan gambar mendeteksi lima fitur utama *PDR*, dengan *NV* diklasifikasikan menggunakan *TensorFlow Inceptionv3*. Kinerja diuji pada 437 gambar *Messidor*, 68 gambar *PDR* dari *Kaggle*, dan 30 gambar *PDR* dari berbagai *dataset* [8].

Penelitian Mehdi Neshtat, Muktar Ahmed, Hossein (2024), dengan judul “*Hybrid Inception Architecture with Residual Connection: Fine-tuned Inception-ResNet Deep learning Model for Lung Inflammation Diagnosis from Chest Radiographs*” menggunakan model *Inception-resnet* dengan tujuan untuk dapat melakukan identifikasi pada inflasi paru – paru menggunakan gambar. Penelitian ini, menyimpulkan bahwa model *Inception-ResNet* unggul dibandingkan dengan tujuh model CNN mutakhir lainnya dalam ekstraksi fitur dan efisiensi komputasi. Penelitian juga mengevaluasi dampak transfer learning dan fine-tuning untuk meningkatkan kinerja model konvolusi mendalam [9].

Penelitian Fitriana Masruroh, Bayu Surarso, Budi Warsito (2023) dengan judul “Perbandingan kinerja *Inception-resnetv2*, *xception*, *Inceptionv3*, dan *resnet50* pada gambar bentuk wajah”, memiliki tujuan untuk membandingkan beberapa model dalam mendeteksi rupa wajah. Penelitian tersebut menyimpulkan bahwa arsitektur CNN *Inception-ResNetV2* optimizer Nadam mencapai akurasi 92,0% dalam 65 menit untuk klasifikasi bentuk wajah, menjadikannya sebagai metode paling efektif diantara metode lainnya [10].

Penelitian Andrew Handri Santoso (2022) dengan judul “*Compare VGG19, ResNet50, Inception-V3 for review food rating*”, Penelitian ini mengevaluasi arsitektur CNN, *VGG19*, *ResNet50*, dan *InceptionV3* untuk memprediksi penilaian produk makanan dari gambar, memperluas analisis sentimen dari teks ke gambar [11].

Penelitian Nur Aini, Dewi Yanti Liliana (2022) dengan judul “Prediksi *Gender* Berdasarkan Citra Mata Menggunakan Metode *Convolutional Neural Network, Inception* dan *MobileNet*”. Studi ini menyimpulkan bahwa model CNN dengan *transfer learning* dan tiga *hidden layer* efektif untuk klasifikasi *gender*. *InceptionV3* dan *MobileNet* menunjukkan akurasi tinggi, dengan pengoptimal Adam meningkatkan hasil [12].

Penelitian Prima Nugraha, Agus Komarudin, Edvin Ramadhan (2023), dengan judul “Deteksi Objek dan Jenis Burung Menggunakan *Convolutional Neural Network* Dengan Arsitektur *Inception Resnet-v2*”, Penelitian ini mengembangkan sistem deteksi burung dengan arsitektur *Inception ResNet V2*, mencapai akurasi 98,28% dengan citra RGB dan learning rate 0.001. Penggunaan RGB lebih unggul dibandingkan grayscale, meskipun penambahan *Gaussian noise* menurunkan akurasi [13].

Penelitian Arif Supriyanto, Wisnu Ananta Kusuma, Hendra Rahmawan (2022) dengan judul “Klasifikasi Kanker Tumor Payudara Menggunakan Arsitektur *Inception-V3* Dan Algoritma *Machine learning*”, bertujuan untuk mendeteksi tumor dalam payudara menggunakan *machine learning*. Berdasarkan hasil penelitian, metode terbaik untuk klasifikasi kanker payudara adalah Kombinasi ekstraksi fitur menggunakan *inceptionV3* bersama

dengan klasifikasi *Logistic Regression* pada data dengan skala *zoom* 40X memberikan hasil yang kuat, mencapai akurasi 93,00%, presisi 94,00%, *recall* 91,00%, dan *F1-score* 92,00%. Di sisi lain, pendekatan *fine-tuning inceptionV3* dengan konfigurasi 164 *layer* dan 100 *epoch* menunjukkan performa yang lebih rendah, dengan akurasi 90,00%, *recall* 91,00%, *F1-score* 82,00%, dan presisi 78,00% [14].

Berdasarkan perbandingan pada penelitian artikel ilmiah sebelumnya, diputuskan bahwa pada penelitian ini akan menggunakan model *InceptionV3* untuk melakukan identifikasi gambar dalam menentukan kategori gambar, dalam kategori *fragile* atau *non-fragile*, dikarenakan model *inceptionV3* yang fleksibel dan menggunakan lapisan *convolutional* 1 x 1 yang sesuai untuk klasifikasi sederhana, dengan akurasi yang tinggi untuk klasifikasi gambar.

III. METODE

Penelitian ini menggunakan metode penelitian SDLC atau *Software Development Lifecycle*, yang merupakan pendekatan yang terstruktur untuk merancang dan mengembangkan perangkat lunak [15]. SDLC digunakan dalam perancangan model dan *website*. SDLC yang digunakan pada penelitian ini meliputi:

A. Requirement

Melakukan pengumpulan kebutuhan dan analisa dari target pengguna terhadap *website* yang dirancang dengan tujuan untuk memahami fungsi utama yang harus dimiliki *website* tersebut [16]. Hasil dari tahap ini adalah dokumentasi spesifik kebutuhan, yang mencakup termasuk fungsionalitas, dan performa yang akan dijadikan acuan pada tahap berikutnya.

Proses disusun dalam bentuk formulir berdasarkan keinginan pengguna dalam pemakaian aplikasi ini. Tabel 1 berikut merupakan *requirement elicitation* yang digunakan pada penelitian ini.

TABEL 1
REQUIREMENT ELICITATION

No	Keinginan user dalam perancangan sistem
1	Interface yang menarik
2	Interface yang mudah dipahami
3	Identifikasi gambar yang akurat
4	Sistem yang mudah dipahami
5	Dapat memudahkan pekerjaan
6	Adanya fitur pengelompokan secara otomatis
7	Terdapat fitur <i>history</i>
8	Data yang disimpan di <i>database</i>
9	Dapat diakses dari berbagai kondisi
10	Data yang dihasilkan dan dikelompokan dapat di- <i>export</i>
11	Dapat memberikan data detail seperti tanggal dan jam barang tersebut di-identifikasi

B. Design

Pada tahap ini, merupakan perancangan dan pembuatan arsitektur *website* [17]. Tahap ini, termasuk pembuatan desain *interface* dan struktur *back-end* pada *website*, hal ini mencakup alur dari pengguna ke model lalu tampilan hasil atau *label*. *User interface* dirancang untuk memberikan visual kepada pengguna dalam menggunakan *website*.

C. Development

Dalam *development*, merupakan tahap penerapan atau pembuatan *front-end* dan *back-end*, implementasi kode, serta integrasi model [18]. *Back-end* dirancang agar *website* dapat berjalan seperti yang diharapkan, dan *front-end* sebagai mediasi pengguna untuk menggunakan *website* dalam mengunggah gambar yang akan dideteksi model yang diterapkan.

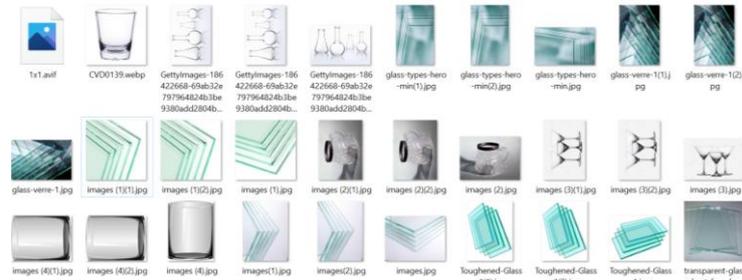
Tahapan ini, juga mencakup reduksi data dari data-data yang tidak diperlukan atau tidak memiliki peran dalam pembuatan *model*. Setelah data di reduksi, data kemudian akan masuk dalam proses augmentasi data, pada proses tersebut, yang mana gambar atau data akan dirotasi secara *vertical*, *horizontal* maupun *invert*.

1) Reduksi Data

Pada proses ini, data atau gambar yang sudah disiapkan akan dilakukan reduksi, yang mencakup mengurangi jumlah gambar yang tidak sesuai, seperti gambar yang memiliki *contrast* yang terlalu tinggi, gambar *blur*, gambar yang tidak sesuai, dan ukuran gambar yang terlalu besar. Total gambar dari 2800 gambar, direduksi menjadi 2202 gambar. Proses ini sendiri bertujuan untuk mengurangi dan menghindari gambar dengan detail yang tidak relevan (seperti *pixel noise*) bisa mendominasi. Reduksi membantu menghapus informasi berlebih yang tidak penting bagi klasifikasi *fragile* dan *non-fragile*.

2) Data Augmentation

Pada proses augmentasi, gambar akan dirotasi secara *vertical*, *horizontal* maupun *invert*. Gambar juga akan diaugmentasi *contrast* dan *brightness* pada gambar. Gambar 1 merupakan *dataset* setelah melalui proses augmentasi. Pada tahap ini, membantu mensimulasikan arsitektur model pada kondisi dunia nyata, seperti sudut pandang, pencahayaan, atau posisi objek. Hal ini penting untuk memastikan model mampu mendeteksi objek dalam berbagai situasi.



Gambar 1 Data Setelah melalui Proses Augmentasi

D. Testing

Tahap *testing* bertujuan untuk memastikan kinerja dan fungsi komponen dari *website* berjalan dengan baik dan sesuai dari yang diharapkan [19]. Setiap bagian diuji menggunakan secara manual, *integration testing*, *user acceptance testing*, dan *performance testing*.

1) Integration Testing

Bertujuan untuk menguji apakah *back-end* dan *front-end* dari website saling terhubung satu sama lain. Pada penelitian ini, pengujian ini memastikan arsitektur model *inceptionV3* terhubung dengan *front-end* website, dan dapat memberikan hasil klasifikasi terhadap gambar dari *user*.

2) User Acceptance Testing

Pengujian ini memastikan apakah produk sudah sesuai dengan *demand* dari *user*. Pada penelitian ini, tanggapan dari *user* diperoleh menggunakan kusioner yang merujuk pada tabel 2, tahap *maintenance*, Dengan menggunakan skala *likert* untuk memberikan total presentase dari *user*.

3) Performance Testing

Pada pengujian ini, bertujuan untuk mengetahui performa dari sistem, hal ini merujuk pada akurasi model yang digunakan, serta apakah model dapat memberikan hasil klasifikasi yang akurat.

Pengujian ini bertujuan untuk memastikan keakuratan model, responsivitas *website*, dan keandalan antarmuka. sehingga *website* mencapai stabilitas sebelum di-deploy. Data yang digunakan merupakan gambar *visual* yang didapat dari internet, dimana gambar kemudian akan digolongkan menjadi dua kelompok, data *training* dan data untuk *testing*. Dari sekitar 1900 Gambar, 70% akan digunakan untuk *training* dan 30% lainnya untuk *testing*. Penggunaan *ratio* 7:3 ini, didapatkan dari hasil *training* dan *testing* model, yang memberikan hasil akurasi lebih tinggi dibandingkan *ratio* lainnya dengan akurasi sebesar 98%. Seperti *ratio* 8:2 yang hanya memberikan akurasi sebesar 94%.

E. Deployment

Pada tahap ini, aplikasi diterapkan menggunakan *localhost* untuk melakukan *debugging* secara menyeluruh. *Back-end* serta model menggunakan *host* pada server lokal untuk memastikan respon dan integrasi sistem berjalan dengan lancar. Pengujian *end-to-end* juga dilakukan dengan berbagai skenario, baik dari sisi antarmuka pengguna maupun sisi server [20], Hal ini bertujuan untuk memastikan sistem berjalan dengan baik bagi pengguna.

F. Maintenance

Setelah aplikasi beroperasi, dilakukan *maintenance* secara rutin untuk memastikan performa dan akurasi model tetap terjaga, memperbaiki *bug*, mengamankan data, serta menyesuaikan fitur berdasarkan respon atau tanggapan dari pengguna. Proses pemeliharaan ini juga melibatkan pemantauan performa, optimasi sistem, dan evaluasi kebutuhan pengguna, sehingga *website* dapat terus berfungsi secara optimal dan dapat menyesuaikan kebutuhan pengguna setelah menggunakan *website* [21].

Kusioner digunakan sebagai mediasi pengumpulan data atau sebagai survey yang dilakukan untuk mengambil tanggapan target pengguna pada website yang dirancang. Kusioner menggunakan media Google Form, berjalan selama 14 hari, dan berhasil mengambil data sebanyak 7 responden. Pertanyaan dari kusioner dapat mengacu pada tabel 2 berikut.

TABEL 2
PERTANYAAN KUSIONER

No	Pertanyaan
1	Apakah <i>website</i> ini dapat memberikan hasil klasifikasi yang akurat?
2	Apakah penggunaan dari <i>website</i> ini dapat dengan mudah dimengerti?
3	Apakah penggunaan dari <i>website</i> ini dapat membantu dalam pengelompokan barang?
4	Apakah dengan adanya <i>website</i> ini, dapat mencegah adanya kerusakan barang?
5	Apakah sistem klasifikasi gambar ini dapat membantu dalam kegiatan sehari – hari?
6	Jika anda sebagai pengguna yang bekerja di bidang pengiriman, apakah <i>website</i> ini dapat meningkatkan efisiensi pekerjaan anda?
7	Kepuasan anda dalam penggunaan <i>website</i> ini.

IV. RESULTS

A. Persiapan Model

Model yang digunakan, *InceptionV3*, menggunakan 1482 gambar visual untuk melakukan *training* model, 467 gambar visual untuk *testing* dan 653 gambar visual untuk *validation*. Model disiapkan menggunakan *Visual Studio Code*.

Dengan *library* yang digunakan, serta menggunakan *dataset* gambar visual yang sudah disiapkan, model kemudian akan melalui proses *training*, dalam proses *training* ini, model menggunakan 1482 gambar, dan 653 gambar untuk validasi, yang berfungsi untuk mengatur dan mengoptimasi *hyperparameters* seperti, *learning rate*, jumlah *layer*, ukuran *batch*, dengan tujuan utama untuk improvisasi model tanpa adanya *overfitting*.

Pada proses *training*, model kemudian akan melalui proses *testing* menggunakan 467 gambar visual, dari hasil *testing* ini, model *inceptionV3* mendapat nilai *metrics* seperti pada gambar 2, dengan hasil, nilai akurasi mencapai 98,4%, skor *precision* sebesar 0.9847, skor *recall* mencapai 0.9842, dan skor F1 sebesar 0.9842. Nilai *precision* dan *recall* yang hampir sama menunjukkan bahwa model tidak bias terhadap salah satu kelas (*fragile* atau *non-fragile*), sehingga performanya konsisten di kedua kategori, dan Skor F1 0.9842 menyimpulkan, bahwa model memiliki kinerja yang konsisten dan seimbang.

Metrics:				
	Accuracy	Precision	Recall	F1 Score
0	98.425197	0.984786	0.984252	0.984274

Gambar 2 Nilai *metrics*.

Skor ini dinilai cukup tinggi jika dibandingkan dengan model yang digunakan pada penelitian lain, seperti pada penelitian Fitriana Masruroh, Bayu Surarso, Budi Warsito (2023), yang menggunakan *Inception-ResNetV2* dalam menentukan bentuk wajah, dengan akurasi 92% [10]. Atau penelitian Arif Supriyanto, Wisnu Ananta Kusuma, Hendra Rahmawan (2022) yang menggunakan arsitektur model yang sama dengan penelitian ini, yaitu *inceptionV3* dalam mendeteksi tumor payudara, memiliki akurasi dan skor *metrics* 90% sampai 94% [14].

B. Penerapan Website dan Tampilan Website

Website dibangun menggunakan *localhost* dengan *Visual Studio Code* sebagai program. *Website* ini dibangun sebagai sarana pengguna untuk menggunakan model *inceptionV3* tanpa harus menggunakan API yang masih awam pada target pengguna, hal ini dinilai lebih *user friendly* pada kasus ini. Tampilan utama *website* sendiri berfungsi sebagai mediasi informasi kepada pengguna, mengenai barang dan apa yang membuat barang tersebut sebagai *fragile* atau *non-fragile*.

Sebelum *website* dibuat, model dipersiapkan dan diterapkan pada *back-end website* terlebih dahulu, seperti pada gambar 3. Pada gambar tersebut, code berfungsi utama untuk menghubungkan model *inceptionV3* yang ada pada *back-end* dengan *front-end* dari *website*, dan bertugas untuk menerima *input* gambar dan memberikan klasifikasi terhadap barang dari gambar yang di-*input* oleh pengguna.

```
import tensorflow as tf
from tensorflow.keras.applications.inception_v3 import preprocess_input
from tensorflow.keras.preprocessing import image
import numpy as np

# Load the custom trained model
model_path = r'C:\Users\Jason\Desktop\skripsi\tf2\out\InceptionV3_S6D_6class.h5'
model = tf.keras.models.load_model(model_path)

# Load and preprocess the image
img_path = r'C:\Users\Jason\Desktop\skripsi\tf2\run\2.jpg'
img = image.load_img(img_path, target_size=(299, 299))
img_array = image.img_to_array(img)
img_array = np.expand_dims(img_array, axis=0)
img_array = preprocess_input(img_array)

# Make predictions
predictions = model.predict(img_array)

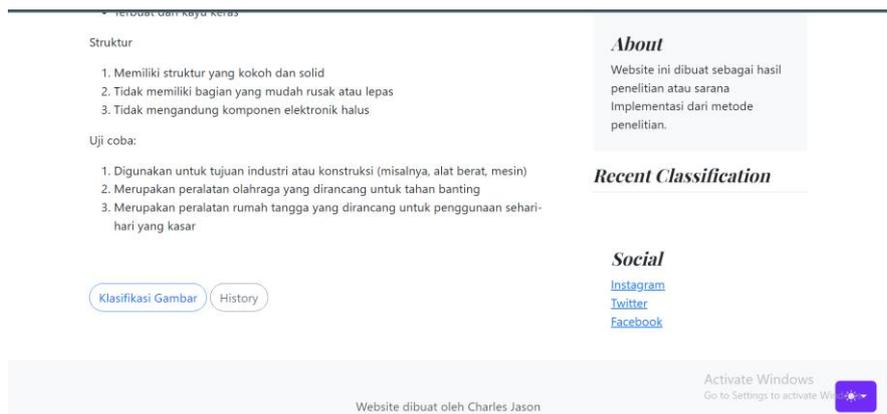
# Assuming the output is a probability distribution for the two classes
class_labels = ['fragile', 'non_fragile']
predicted_class = class_labels[np.argmax(predictions[0])]
confidence = np.max(predictions[0])

print(f"Predicted class: {predicted_class} ({confidence * 100:.2f}%)")
```

Gambar 3 Penerapan model.

1. Halaman Utama Website

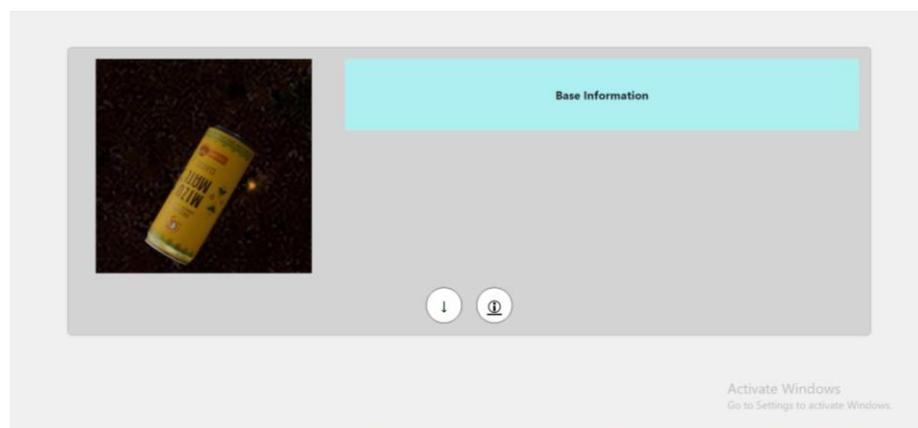
Tampilan utama dari website ini berfungsi sebagai penyedia informasi atau memberikan edukasi terhadap pengguna tentang apa yang menentukan atau mengklasifikasikan suatu barang menjadi barang *fragile* atau *non-fragile*. Hal ini bertujuan untuk menghindari adanya kebingungan terhadap hasil klasifikasi model yang diberikan.



Gambar 4 Tombol klasifikasi dan *history* gambar.

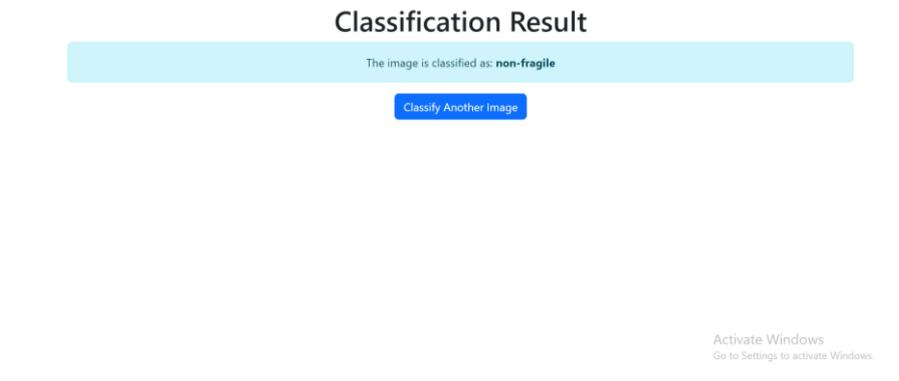
2. Tampilan Klasifikasi

Pada gambar 4, dengan menekan tombol klasifikasi gambar, pengguna dapat masuk kedalam halaman klasifikasi gambar, dan beralih pada halaman gambar 5 berikut.



Gambar 5 *Input* gambar.

Pengguna dapat menekan tombol + untuk dapat *input* gambar visual yang ingin diklasifikasi, gambar yang sudah di *input* kemudian akan muncul seperti pada gambar 5 dan dapat segera dilakukan proses klasifikasi. Pengguna dapat menekan tombol ‘i’ untuk melakukan klasifikasi dan memunculkan hasil seperti pada gambar 6. Hasil klasifikasi yang diberikan, dinilai cukup akurat berdasarkan nilai *metrics* pada gambar 2.



Gambar 6 Tampilan halaman klasifikasi 3

C. Hasil Survey Pengguna

Data atau hasil survey yang dilakukan selama 14 hari, ditampilkan menggunakan skala *likert*. Dari 7 pertanyaan, pengguna diberikan pilihan dari 5 jawaban, dengan masing-masing skor pada jawaban sebagai berikut:

TABEL 3
 SKOR SKALA *LIKERT*

Kategori	Skor
STS	1
ST	2
R	3
S	4
SS	5

Dengan keterangan sebagai berikut:

- SS = Sangat Setuju
- S = Setuju
- R = Ragu
- TS = Tidak Setuju
- STS = Sangat Tidak Setuju

Berdasarkan hasil jawaban dari survey yang telah dibagikan, berikut ini hasil jawaban yang diperoleh, dari total 7 pertanyaan yang diajukan kepada para responden, diterima berbagai tanggapan yang terdiri dari: 19 respons sangat setuju, 15 respons setuju, 7 respons ragu-ragu, 0 respons tidak setuju, dan 1 respons sangat tidak setuju.

Skor final skala *likert* yang didapat:

TABEL 4
 SKOR AKHIR SKALA *LIKERT*

Pertanyaan	Skor
1	21
2	28
3	22
4	23
5	27
6	25
7	26

$$\begin{aligned} \text{Skor akhir} &= 172 \\ n &= 7 \\ \text{Rumus} &= \text{Skor akhir}/n \end{aligned}$$

$$\begin{aligned} \text{Skor akhir skala } \textit{likert} &= 172/7 \\ &= 24.5 \text{ atau } 81.9\% \end{aligned}$$

Berdasarkan tabel 4 dan dari perhitungan hasil skor akhir, *rating* dari pengguna *website* yang diambil menggunakan survey melalui *google form* menunjukkan hasil positif di area (Setuju), dengan *rating* mencapai 81.9%, diharapkan untuk *website* ini sebagai alternatif solusi pada masalah di bidang pengiriman, dan dapat membantu dalam memberikan klasifikasi barang *fragile* dan *non-fragile*.

V. PEMBAHASAN

Penelitian ini menggunakan *inceptionV3* sebagai model untuk melakukan klasifikasi gambar visual, model ini menentukan label untuk klasifikasi gambar dari *dataset* visual yang digunakan untuk *training* dan *testing*, Semakin banyak gambar yang digunakan, semakin tinggi akurasi hasil klasifikasi yang diperoleh. Dari 2202 gambar yang digunakan untuk membuat model *inceptionV3*, akurasi klasifikasi dapat mencapai 94% hingga 98%.

Penelitian ini juga mengambil referensi dari penelitian terdahulu yang memakai model serupa, seperti penelitian yang dilakukan Fitriana Masrurroh, Bayu Surarso, Budi Warsito (2023) dan Handri Santoso (2022), yang khususnya menggunakan lebih dari satu model dan melakukan perbandingan antar model tersebut, dari perbandingan tersebut, *inceptionV3* memiliki keunggulan dan memberikan kebutuhan yang dibutuhkan pada penelitian ini, yaitu melakukan klasifikasi gambar yang lebih akurat pada klasifikasi 2 label, dengan skala gambar yang besar untuk digunakan pada *training* model, sehingga memberikan nilai akurasi yang lebih tinggi dibanding model lainnya.

Kekuatan atau kelebihan dari penelitian ini merupakan pengguna yang dapat dengan mudah menggunakan *website* yang tergolong *user friendly* kepada pengguna yang tidak mengetahui memiliki pengetahuan terhadap *machine learning*. Dengan akurasi diatas 90%, pengguna dapat mempercayai hasil klasifikasi yang disajikan *website*. Temuan dari penelitian ini dapat memberikan pengguna yang bekerja di bidang pengiriman keunggulan dalam mengelompokkan barang secara otomatis dengan cara memberikan label klasifikasi kepada barang tersebut dengan upaya menghindari adanya kesalahan dalam pengelompokan barang.

Kepada penelitian kedepannya, diharapkan peneliti dapat menambah skala gambar visual yang digunakan untuk *training* model *inceptionV3*, dikarenakan kelemahan dari model ini sendiri merupakan seberapa besarnya skala yang digunakan pada saat *training* model. Skala gambar visual, diharapkan mencakup faktor seperti, barang atau objek dalam sinar matahari, objek target disamping objek lain, atau objek dalam bentuk rusak atau cacat. Peneliti juga diharapkan menggunakan lebih dari satu model, seperti *ResNet-50* yang menunjukkan hasil akurasi yang tinggi.

VI. KESIMPULAN

Klasifikasi gambar otomatis, khususnya dalam mengelompokkan barang kedalam dua kelompok, dapat memanfaatkan teknologi *machine learning* menggunakan *inceptionV3*. Model ini memiliki performa unggul dalam klasifikasi sederhana seperti klasifikasi untuk dua label, sesuai dengan temuan penelitian sebelumnya. Dengan antarmuka *website* yang tergolong ramah pada pengguna, memungkinkan orang tanpa latar belakang *machine learning* untuk mengandalkan hasil klasifikasi. Penelitian diharapkan dapat menjadi alternatif pada masalah dalam industri pengiriman, di mana otomatisasi pengelompokan barang dapat mengurangi potensi kesalahan. Adapun saran yang dapat digunakan pada penelitian selanjutnya adalah untuk meningkatkan variasi *sample* dan memperbesar *dataset* pada saat perancangan model, hal ini bertujuan agar model dapat memberikan hasil klasifikasi yang akurat pada variasi objek gambar, serta menyertai penggunaan model lain, seperti *ResNet-50* atau *Inception-ResNetV2*, guna meningkatkan akurasi klasifikasi pada aplikasi nyata, terutama untuk klasifikasi dengan skala yang lebih luas.

DAFTAR PUSTAKA

- [1] S. Park, Y. Xu, L. Jiang, Z. Chen, and S. Huang, "Spatial structures of tourism destinations: A trajectory data mining approach leveraging mobile big data," *Ann. Tour. Res.*, vol. 84, no. January, p. 102973, 2020, doi: 10.1016/j.annals.2020.102973.
- [2] S. Somadi, B. S. Priambodo, and P. R. Okarini, "Evaluasi Kerusakan Barang dalam Proses Pengiriman dengan Menggunakan Metode Seven Tools," *J. INTECH Tek. Ind. Univ. Serang Raya*, vol. 6, no. 1, pp. 1–11, 2020, doi: 10.30656/intech.v6i1.2008.
- [3] T. Wahyudi, "Pengembangan Aplikasi Berbasis Web dan Android Sebagai Penunjang Kerja di Indonesia: Systematic Literature Review," *Indones. J. Comput. Sci.*, vol. 1, no. 2, pp. 96–102, 2022, doi: 10.31294/ijcs.v1i2.1428.
- [4] Wijoyo A, Saputra A, Ristanti S, Sya'ban S, Amalia M, and Febriansyah R, "Pembelajaran Machine Learning," *OKTAL (Jurnal Ilmu Komput. dan Sci.*, vol. 3, no. 2, pp. 375–380, 2024, [Online]. Available: <https://journal.mediapublikasi.id/index.php/oktal/article/view/2305>
- [5] R. G. Wardhana, G. Wang, and F. Sibuea, "Penerapan Machine Learning Dalam Prediksi Tingkat Kasus Penyakit Di Indonesia," *J. Inf. Syst. Manag.*, vol. 5, no. 1, pp. 40–45, 2023, doi: 10.24076/joism.2023v5i1.1136.

- [6] A. Roihan, P. A. Sunarya, and A. S. Rafika, "Pemanfaatan Machine Learning dalam Berbagai Bidang: Review paper," *IJCIT (Indonesian J. Comput. Inf. Technol.*, vol. 5, no. 1, pp. 75–82, 2020, doi: 10.31294/ijcit.v5i1.7951.
- [7] U. UNGKAWA and G. AL HAKIM, "Klasifikasi Warna pada Kematangan Buah Kopi Kuning menggunakan Metode CNN Inception V3," *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron.*, vol. 11, no. 3, p. 731, 2023, doi: 10.26760/elkomika.v11i3.731.
- [8] M. A. I. Mahmood, N. Aktar, and M. F. Kader, "A hybrid approach for diagnosing diabetic retinopathy from fundus image exploiting deep features," *Heliyon*, vol. 9, no. 9, Sep. 2023, doi: 10.1016/j.heliyon.2023.e19625.
- [9] M. Neshat, M. Ahmed, H. Askari, M. Thilakarathne, and S. Mirjalili, "Hybrid Inception Architecture with Residual Connection: Fine-tuned Inception-ResNet Deep Learning Model for Lung Inflammation Diagnosis from Chest Radiographs," in *Procedia Computer Science*, 2024, vol. 235, pp. 1841–1850. doi: 10.1016/j.procs.2024.04.175.
- [10] F. Masrurroh, B. Surarso, B. Warsito, and P. Korespondensi, "PERBANDINGAN KINERJA INCEPTION-RESNETV2, XCEPTION, INCEPTION-V3, DAN RESNET50 PADA GAMBAR BENTUK WAJAH PERFORMANCE COMPARISON OF INCEPTION-RESNETV2, XCEPTION, INCEPTION-V3, AND RESNET50 ON FACE SHAPE IMAGES," vol. 10, no. 1, pp. 11–20, 2023, doi: 10.25126/jtiik.2023104941.
- [11] A. Andrew and H. Santoso, "Compare VGG19, ResNet50, Inception-V3 for Review Food Rating," *Sinkron*, vol. 7, no. 2, pp. 845–494, Apr. 2022, doi: 10.33395/sinkron.v7i2.11383.
- [12] N. Aini and D. Y. Liliana, "Prediksi Gender Berdasarkan Citra Mata Menggunakan Metode Convolutional Neural Network, Inception dan MobileNet," *Bul. Poltanesa*, vol. 23, no. 1, Jun. 2022, doi: 10.51967/tanesa.v23i1.1272.
- [13] P. Nugraha, A. Komarudin, E. Ramadhan, U. Jenderal, A. Yani, and C. Ji, "DETEKSI OBJEK DAN JENIS BURUNG MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK DENGAN ARSITEKTUR INCEPTION RESNET-V2", doi: 10.31949/infotech.v8i2.2889.
- [14] A. Supriyanto, W. A. Kusuma, and H. Rahmawan, "Klasifikasi Kanker Tumor Payudara Menggunakan Arsitektur Inception-V3 Dan Algoritma Machine Learning," *J. Al-AZHAR Indones. SERI SAINS DAN Teknol.*, vol. 7, no. 3, p. 187, Sep. 2022, doi: 10.36722/sst.v7i3.1284.
- [15] B. S. Nagara, D. Oetari, Z. Apriliani, and T. Sutabri, "Penerapan Metode SDLC (System Development Life Cycle) Waterfall Pada Perancangan Aplikasi Belanja Online Berbasis Android Pada CV Widi Agro," *INTECOMS J. Inf. Technol. Comput. Sci.*, vol. 6, no. 2, pp. 1202–1210, 2023, doi: 10.31539/intecomsv6i2.8244.
- [16] M. M. Lucini, P. J. Van Leeuwen, and M. Pulido, "Model error estimation using the expectation maximization algorithm and a particle flow filter," *SIAM-ASA J. Uncertain. Quantif.*, vol. 9, no. 2, pp. 681–707, 2021, doi: 10.1137/19M1297300.
- [17] Z. Ariza, "Perancangan Sistem Informasi Penilaian Angka Kredit Kenaikan Jabatan Fungsional Atau Pangkat Dosen di Fakultas Tarbiyah Dan Ilmu Keguruan UIN Bukittinggi," *J. Inf. Syst. Educ. Dev.*, vol. 2, no. 1, pp. 13–19, 2024, doi: 10.62386/jised.v2i1.50.
- [18] M. M. Banin, "Perancangan Sistem Informasi Untuk Mengontrol Sistem Pembelian, Persediaan Dan Penjualan Dengan Menggunakan Metode System Development Life Cycle (SDLC)," *Integr. J. Ilm. Tek. Ind.*, vol. 6, no. 2, p. 89, 2021, doi: 10.32502/js.v6i2.3994.
- [19] F. Rahmat Halim *et al.*, "Rancang Bangun Sistem Informasi Pengumuman Kelulusan Siswa Berbasis Web Menggunakan Metode Agile Web-Based Student Graduation Announcement Information System Design Using the Agile Method," *J. Test. dan Implementasi Sist. Inf.*, vol. 1, no. 2, pp. 67–81, 2023.
- [20] N. Nilma, "Penerapan Model Software Development Life Cycle Pada Rancang Bangun Sistem Payroll Perusahaan," *J. Publ. Tek. Inform.*, vol. 1, no. 2, pp. 61–69, 2022, doi: 10.55606/jupti.v1i2.334.
- [21] F. N. Ramadha, E. D. Wahyuni, and D. D. Vannes, "SDLC Big Bang dan Waterfall: Perbandingan Pendekatan dalam Pengembangan Perangkat Lunak," *Nuansa Inform.*, vol. 18, no. 2, pp. 41–45, 2024, doi: 10.25134/ilkom.v18i2.158.