

# Pengaplikasian Convolutional Neural Network (MobileNetV3) Memanfaatkan Transfer Learning Untuk Membedakan Tanaman Cabai Berasal Dari Genus *Capsicum Annuum*

Tomi Tri Sujaka\*, I Nyoman Switrayana, Ibnu Mumtaz Haepa Fillah

Fakultas Teknik, Program Studi Ilmu Komputer, Universitas Bumigora, Mataram, Indonesia  
Email: <sup>1,\*</sup>tomi\_tri@universitasbumigora.ac.id, <sup>2</sup>nyoman.switrayana@universitasbumigora.ac.id,  
<sup>3</sup>2201010101@universitasbumigora.ac.id

Email Penulis Korespondensi: tomi\_tri@universitasbumigora.ac.id  
Submitted: 18/11/2025; Accepted: 16/12/2025; Published: 16/12/2025

**Abstrak**—Klasifikasi variasi dari *Capsicum annuum* yang akurat penting untuk aplikasi industri pangan, dan penelitian dibidang agrikultura. Metode klasifikasi manual tradisional memakan waktu, subjektif, kurang detail dan rentan terhadap kesalahan manusia, sehingga memerlukan ilmu komputer vision untuk melakukan otomatisasi tersebut. Penelitian ini menyajikan pembelajaran dalam bentuk klasifikasi otomatis sembilan variasi *Capsicum annuum* yang beragam menggunakan transfer learning dengan arsitektur MobileNetV3, yang dirancang untuk mendapatkan akurasi tinggi dan efisien secara energi komputasi. Dataset tersusun dari 4.500 citra (dibagi menjadi 85% untuk cross-validation dan 15% untuk hold-out testing) dari 9 varisi cabai: bell pepper, cabe keriting, cherry pepper, chiltepin, hungarian wax, jalapeno, marconi, pequin, dan cabai Thailand. Dataset ini melalui quality control salah satunya adalah dataset balancing. Model pada penelitian ini juga sudah dioptimalisasi dengan Adam (Adaptive Moment Estimation). Interpretasi model juga ditingkatkan melalui visualisasi Grad-CAM dan model robustness juga sudah divalidasi menggunakan cross-validation sebanyak 5 kali. Model ini mencapai kinerja dengan akurasi training 97,1%, akurasi testing 95,1%, dan uji validasi 94,8%, dimana cross validation sebanyak 5 kali menunjukkan hasil konsisten ( $94,23\% \pm 1,45\%$ ). Analisis Grad-CAM menunjukkan bahwa model ini fokus pada fitur struktur seperti bentuk, tekstur permukaan, dan pola warna. Dengan berhasil dikembangkannya sistem AI yang dapat mengidentifikasi varisi cabai secara otomatis dengan akurasi 95,1%. Sistem ini bekerja dengan baik dalam kondisi nyata (akurasi 90,6%) dan praktis untuk penggunaan dibidang pertanian dan pengolahan makanan. Teknologi ini dapat membantu petani dan perusahaan makanan ataupun orang awam untuk memilah cabai secara otomatis, mengurangi biaya, dan meningkatkan kendali mutu.

**Kata Kunci:** *Capsicum Annuum*; Transfer Learning; MobileNetV3; Convolutional Neural Network; Grad-CAM.

**Abstract**—Accurate classification of *Capsicum annuum* varieties is crucial for food industry applications and agricultural research. Traditional manual classification methods are time-consuming, subjective, lack detail, and are prone to human error, requiring computer vision to automate them. This study presents learning in the form of automatic classification of nine diverse *Capsicum annuum* varieties using transfer learning with the MobileNetV3 architecture, which is designed to achieve high accuracy and be computationally energy efficient. The dataset consists of 4,500 images (training, testing, and validation) of 9 chili varieties: bell pepper, curly chili, cherry pepper, chiltepin, Hungarian wax, jalapeno, marconi, pequin, and Thai chili. This dataset goes through quality control, one of which is dataset balancing. The model in this study has also been optimized with Adam (Adaptive Moment Estimation). Model interpretation is also improved through Grad-CAM visualization, and model robustness has also been validated using cross-validation 5 times. This model achieved performance with a training accuracy of 97.2%, a testing accuracy of 95.1%, and a validation test of 94.8%, where 5-fold cross-validation showed consistent results ( $94.23\% \pm 1.45\%$ ). Grad-CAM analysis showed that this model focuses on structural features such as shape, surface texture, and color patterns. With the successful development of an AI system that can automatically identify chili varieties with an accuracy of 95.1%. This system works well in real conditions (90.6% accuracy) and is practical for use in agriculture and food processing. This technology can help farmers and food companies or lay people to sort chilies automatically, reduce costs, and improve quality control.

**Keywords:** *Capsicum Annuum*; Transfer Learning; MobileNetV3; Convolutional Neural Network; Grad-CAM.

## 1. PENDAHULUAN

Di Indonesia, cabai merupakan komoditas hortikultura strategis dengan luas panen mencapai 334,55 ribu hektar dan produksi 3,02 juta ton pada tahun 2022[1]. Fluktuasi produksi yang signifikan pada cabai merah besar dan menyebabkan ketidak stabilan harga yang tinggi[2], menjadikan identifikasi varietas yang akurat sebagai tantangan krusial dalam rantai pasok cabai nasional untuk menjaga stabilitas pasokan dan harga. *Capsicum annuum*, umum dikenal sebagai paprika dan cabai, merupakan salah satu tanaman penting secara ekonomi di dunia, dengan produksi *global* melebihi 36 juta ton per tahun[3]. Identifikasi dan klasifikasi yang akurat dari berbagai variasi *Capsicum* penting untuk berbagai aplikasi pertanian dan komersial, dalam beberapa tahun terakhir teknologi *AI*, telah mencapai kemajuan terobosan dibidang-bidang seperti pengenalan gambar dan deteksi objek, yang memberikan dukungan teknis yang kuat untuk tugas-tugas seperti menilai status tanaman secara akurat, mengidentifikasi berbagai *kultivar*[4].

Klasifikasi secara tradisional bergantung pada penidentifikasi secara manual oleh ahli terlatih mengevaluasi melalui karakteristik morfologi seperti ukuran, bentuk, warna, tekstur permukaan, dan sifat fenotipik lainnya[5]. Namun, pendekatan ini memiliki beberapa keterbatasan yang signifikan[3]: Selama ini masyarakat hanya mampu mengklasifikasikan bentuk dari deskripsi varietas cabai tanpa disertai tampilan fisik berupa foto sehingga cukup menyulitkan bagi masyarakat maupun petani dalam membudidayakan maupun memanfaatkan varietas tersebut [6] proses yang memakan waktu dan tidak bisa diterapkan untuk operasi skala besar kebutuhan akan keahlian khusus [7] dan untuk mengurangi kesalahan manusia memastikan produk tetap konsisten[8] dikarenakan Kegagalan sortir dan

*grading* sayuran segar (termasuk cabai) berdasarkan kualitas fisik menyebabkan kerugian pascapanen 20-40% di *Sri Lanka*. Akibatnya, petani kecil kehilangan keuntungan ekonomi karena pasar sering tidak memberi insentif harga untuk produk berkualitas baik [9].

Aplikasi *Computer Vision* dalam otomasi bidang pertanian semakin berkembang dengan sangat cepat dan semakin canggih[10], salah satunya dalam pengolahan citra digital [11]. Penelitian terdahulu yang mengklasifikasi cabai menggunakan *computer vision* menggunakan 4 kelas dan 1500 total data citra untuk semua kelas dan mendapatkan akurasi sebesar 98% [12], belum adanya implementasi real world untuk yang aplikatif, tentunya ini hasil yang baik dan dapat ditingkatkan lebih lanjut menggunakan algoritma optimasi seperti *adam optimizer* yang terbukti meningkatkan akurasi [13] dan *transfer learning* untuk menggabungkan *feature extraction* pada data dan algoritma klasifikasi [14] yang mana disini adalah *cnn*, agar model optimal dan efisien saat proses pembelajaran [15], Hal ini menunjukkan perlu adanya sistem klasifikasi yang lebih *robust*, akurat, dan dapat diaplikasikan untuk mendukung industri pertanian, Sistem berbasis web menjadi solusi strategis karena dapat diakses melalui smartphone tanpa memerlukan spesifikasi hardware tinggi.

Penelitian ini memiliki fokus pada penerapan algoritma Convolutional Neural Network (CNN) dengan arsitektur MobileNetV3 untuk klasifikasi varietas cabai. Implementasi model dilakukan pada aplikasi berbasis web yang dapat diakses secara online, memberikan kemudahan akses bagi pengguna tanpa memerlukan instalasi perangkat lunak khusus. Validasi model dilakukan menggunakan metode 5-fold cross-validation untuk mensimulasikan kondisi real-world saat aplikasi siap dideploy [16], berbeda dengan penelitian sebelumnya yang hanya menghasilkan model tanpa implementasi aplikasi [12]. Tujuan akhir penelitian ini adalah menjadi solusi yang membantu petani dan stakeholder lainnya dalam mengidentifikasi sembilan varietas cabai dari genus *Capsicum annuum* dengan cepat dan akurat melalui aplikasi berbasis web.

Beberapa penelitian yang relevan dengan penelitian ini telah dilakukan, termasuk penelitian dengan metode yang serupa, baris dari objek ataupun arsitektur yang diteliti [5][7] tetapi letak perbedaan yang signifikan ada pada akurasi, metode, dan *dataset* yang digunakan, penggunaan *mobilenet* dan *transfer learning* telah terbukti memberikan nilai akurasi, *recall*, *precision* dan *f1 score* yang tinggi yaitu keempat peniaian tersebut mendapatkan nilai sebanyak 96%, pada penelitian yang digunakan untuk mengklasifikasikan penyakit dan hama padi[16], untuk meningkatkan model dasar pada penelitian ini *fine tuning* dapat diimplementasikan pada penelitian sebelumnya yang membahas *names entity recognition* menggunakan model *IndoBert* *f1 score* yang didapat 72.38% sebelum diimplementasikannya *fine tuning* setelah *fine tuning* diaplikasikan pada model dasarnya nilai *f1 score* naik secara signifikan memberikan hasil akhir sebesar 83.67%[17], tanpa hasil implementasi nyata *research* ini hanya menjadi sebuah *proof of concept* yang belum mampu menyelesaikan masalah dilapangan karena hasil penelitian menunjukkan bahwa terdapat perbedaan yang signifikan antara apa yang berhasil di lingkungan akademis dan apa yang dibutuhkan oleh sistem dunia nyata[18] setelah mempelajari penelitian yang berkaitan tersebut, maka penelitian ini akan mengklasifikasikan 9 *classes* dari *capsicum annuum* dengan memberikan model dengan akurasi yang tinggi menggunakan metode, parameter yang sudah dibahas dan dapat diimplementasikan secara nyata.

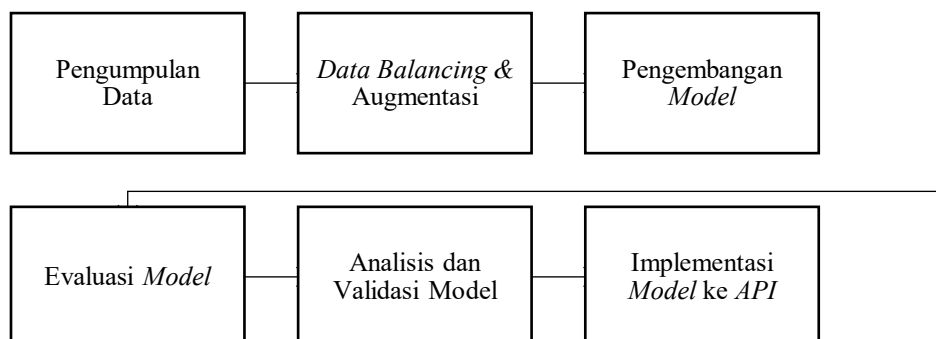
Untuk mencapai tujuan itu, dikembangkannya *model* klasifikasi *deep learning* untuk sembilan varietas *Capsicum annuum* yang terdiri dari:(*bell pepper*, cabe keriting, *cherry pepper*, *chiltepin*, *Hungarian wax*, *jalapeño*, *marconi*, *pequin*, dan *Thai chili*) dengan memanfaatkan arsitektur *MobileNetV3* melalui pendekatan *transfer learning*. Pengemangan *Model* menggunakan dataset yang seimbang sebesar 4.500 citra *split data* menjadi training (70%), *testing* (15%), dan validasi (15%). Untuk memastikan kepastian model, penelitian ini menerapkan *Gradient-weighted Class Activation Mapping (Grad-CAM)*, yang memvisualisasikan *region of interest (ROI)* pada citra yang menjadi fokus model dalam melakukan prediksi, sehingga memberikan transparansi terhadap proses pengambilan keputusan model. Validasi *robustness* dilakukan menggunakan *5-fold cross-validation* untuk mengevaluasi stabilitas dan generalisasi model pada data yang berbeda[19], dilengkapi dengan *robustness test* terhadap berbagai kondisi transformasi citra seperti variasi kecerahan, rotasi, noise, dan blur. Sistem yang dikembangkan diimplementasikan dalam bentuk aplikasi berbasis *web* menggunakan *React.js* sebagai framework *front-end* dan *PyTorch* untuk *deployment model*, memungkinkan pengguna melakukan klasifikasi cabai secara real-time melalui browser dengan interface yang intuitif dan mudah diakses, Integrasi *Grad-CAM* dalam sistem memberikan nilai tambah berupa interpretabilitas yang membantu pengguna memahami keputusan dari model, meningkatkan kepercayaan pengguna terhadap teknologi kecerdasan buatan. Pendekatan dari pengembangan model hingga *deployment* aplikasi *web* menjadi kontribusi utama penelitian, menjembatani gap antara riset akademis dan kebutuhan praktis di lapangan yang selama ini masih terbatas.

Pemilihan arsitektur *MobileNetV3* pada penelitian ini didasarkan pada keunggulannya dalam efisiensi komputasi dan deployment praktis pada perangkat dengan keterbatasan resource. *MobileNetV3* yang cocok untuk aplikasi real-time seperti klasifikasi gambar dan deteksi objek[20]. Arsitektur ini sangat cocok untuk *deployment* pada aplikasi *web* dan *mobile* dengan keterbatasan *resource*, menggunakan teknik seperti *inverted residual blocks* dan *squeeze-and-excitation* yang mengoptimalkan performa tanpa mengorbankan akurasi[21]. Kombinasi *hardware-aware Neural Architecture Search (NAS)* dan *NetAdapt algorithm* menjadikan *MobileNetV3* sebagai pilihan optimal untuk sistem klasifikasi *real-time* dan Implementasi *transfer learning* pada *MobileNetV3* memungkinkan model mencapai tahap konvergensi lebih cepat dengan *data training* yang lebih efisien, mengurangi biaya komputasi hingga 40% dibandingkan *training* tanpa arsitektur yang ada pada CNN (dari scratch), sekaligus mempertahankan akurasi tinggi yang dibutuhkan untuk aplikasi komersial.

## 2. METODOLOGI PENELITIAN

### 2.1 Tahapan Penelitian

Penelitian ini menggunakan *Convolutional Neural Network* (CNN) dengan arsitektur *MobileNet* Versi 3 sebagai algoritma komputasinya, algoritma dan arsitektur tersebut menjadi pilihan, dikarenakan merupakan *bleeding edge* dari arsitektur *mobilenet*, lebih lagi jika diterapkan kepada aplikasi berbasis *website*, proses penelitian ada pada gambar 1 yang menunjukkan rangkaian berikut:



Gambar 1. Rangkaian Penelitian

Penelitian ini dimulai dengan mengumpul data citra cabai dari sembilan varietas *Capsicum annuum*. kemudian, data melalui proses data *balancing* dan *augmentasi* untuk mengatasi ketidakseimbangan kelas dan meningkatkan variasi *dataset*. Tahap pengembangan model kemudian dilakukan dengan merancang arsitektur *MobileNetV3* dan melakukan pelatihan menggunakan *dataset* yang sudah diproses. Evaluasi model dilakukan untuk mengukur performa klasifikasi, dilanjutkan dengan analisis dan validasi menggunakan *5-fold cross-validation* yang memastikan konsistensi dan generalisasi model. Pada tahap akhir, model diimplementasikan ke dalam *API* untuk integrasi dengan aplikasi *web*, sehingga memungkinkan pengguna melakukan klasifikasi varietas cabai secara *real-time*.

### 2.2 Pengumpulan Data

*Dataset* pada penelitian ini berasal dari bermacam – macam sumber yang berada pada halaman *internet* maupun hasil foto pribadi, adapun sumber – sumber tersebut antara lain adalah:

- <https://dhseedharvestco.com>
- <https://www.hrseeds.com>
- <https://www.kaggle.com/datasets/aelchimminut/fruits262/>
- <https://www.gardenersworld.com/>
- Google seach images

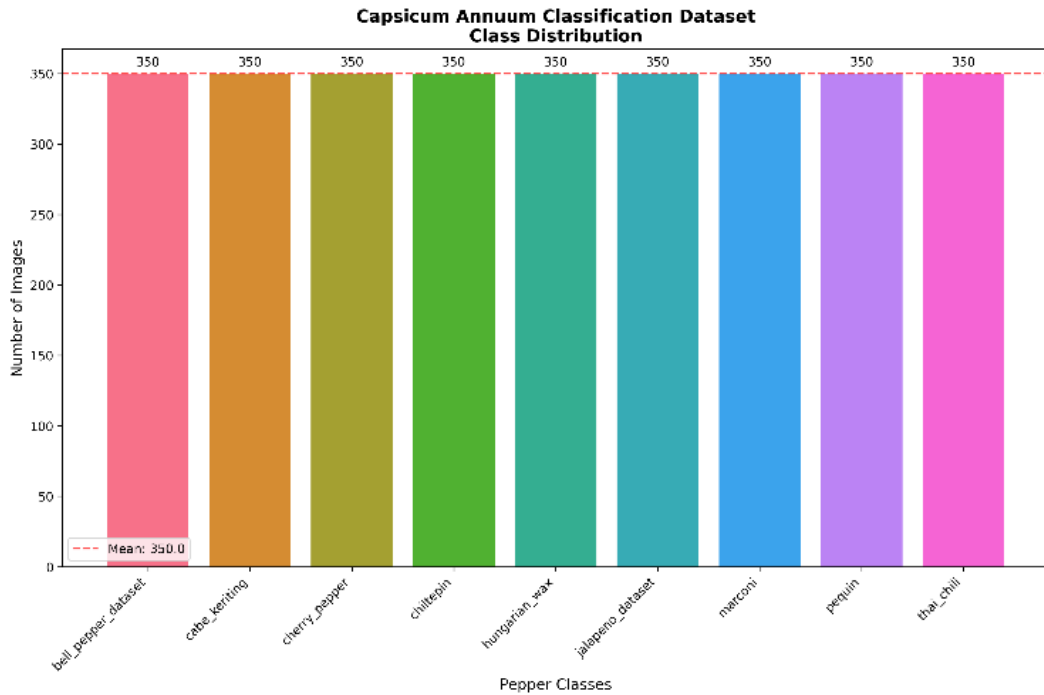
Kumpulan data pada penelitian ini yang berisi 4.500 gambar terdiri dari 9 variasi *Capsicum annuum* yang berbeda telah disusun berdasarkan variasi buah cabai yang diklasifikasikan berdasarkan morfologi, lalu dipilih untuk mewakili cabai yang umum dibudidayakan dengan karakteristik yang bervariasi, antara lain:

- Bell Pepper*, dengan karakteristik: besar berbentuk blok, dan berkulit tebal.
- Cabe Keriting, dengan karakteristik: berbentuk panjang dan berkelok.
- Cherry Pepper*, dengan Karakteristik: kecil seperti buah *cherry*.
- Chiltepin*, dengan karakteristik: kecil seperti manik, berbentuk bulat.
- Hungarian Wax*, dengan Karakteristik: berbentuk panjang dan berisi.
- Jalapeno*, dengan karakteristik: bentuk kerucut, kulit halus dan mengkilap, dan warnanya bervariasi dari hijau hingga merah saat matang.
- Marconi*, dengan karakteristik: berbentuk kotak balok yang meruncing ke bawah.
- Pequin*, dengan Karakteristik: berukuran kecil dan lonjong
- Thai Chili*, dengan karakteristik: layaknya variasi *birdseye*, berbentuk kerucut dan keriput dan berkelok.

### 2.3 Data Balancing dan Augmentasi

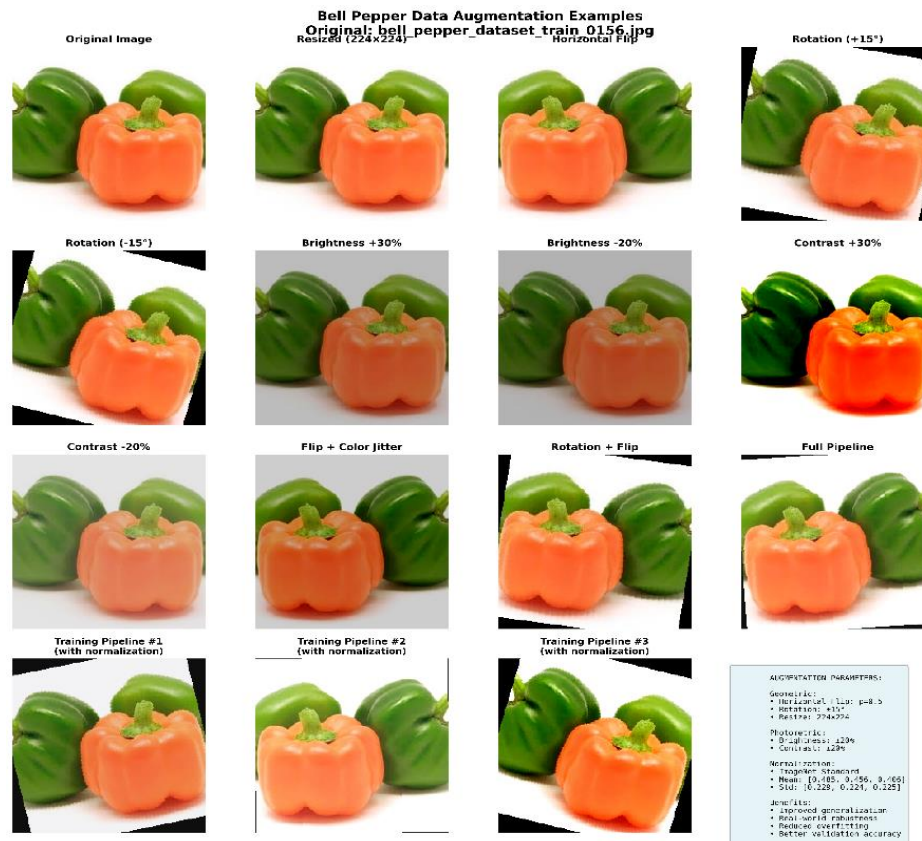
*Dataset* awal terdiri dari 3.698 gambar dengan distribusi yang tidak seimbang antar kelas, dimana jumlah gambar per variasi berkisar antara 290 hingga 500 gambar (Tabel 1). *Data balancing* merupakan teknik *resampling* untuk mengatasi masalah *imbalanced data* yang mencakup *oversampling* (menambah kelas minoritas) melalui *augmentasi data*[22]. Dalam penelitian ini, *augmentasi data* diterapkan pada seluruh kelas untuk mencapai distribusi yang seimbang sebesar 500 gambar per kelas. Kelas minoritas seperti *Cherry Pepper* (290 gambar awal), *Chiltepin* (300 gambar), dan *Thai Chili* (328 gambar) diperbanyak melalui teknik *augmentasi* hingga mencapai 500 gambar, sementara kelas yang sudah memiliki 500 gambar (*Bell Pepper*, *Cabe Keriting*, *Jalapeno*) tetap dipertahankan. Kelas dengan jumlah mendekati 500 seperti *Hungarian Wax* (481 gambar), *Marconi* (422 gambar), dan *Pequin* (377 gambar)

juga dilakukan augmentasi untuk mencapai target 500 gambar per kelas. Setelah balancing, total dataset menjadi 4.500 gambar (9 kelas × 500 gambar), yang kemudian dibagi menjadi 350 gambar untuk training (70%), 75 gambar untuk testing (15%), dan 75 gambar untuk validasi (15%) pada setiap kelas (Tabel 2), dengan alokasi yang proporsional untuk mencegah overfitting.



Gambar 2. Balancing data

Dataset berupa citra yang dibuat proporsional untuk dengan nilai mean setiap variasi berjumlah 350 gambar dan format citra yang serumpun yaitu dalam bentuk *JPG* dengan color model *RGB*(RED, GREEN, BLUE), yang kemudian siap untuk dilanjutkan ke tahap augmentasi citra.



Gambar 3. Augmentasi Citra

Augmentasi Citra dimulai dari pengurangan resolusi gambar menjadi  $224 * 224$  pixel (standar *mobilenetV3*), selanjutnya pengaplikasian normalisasi imagenet seperti penambahan dan pengurangan pencahayaan, *contrast*, merotasi dan membalikan gambar, *color jitter* dan penggabungan dari semua yang telah dilakukan.

## 2.4 Pengembangan Model

Penelitian ini menggunakan dataset citra cabai *genus Capsicum annum* dengan total 4.500 citra yang terdiri dari 9 klasifikasi, dimana setiap kelas memiliki 500 citra. Pembagian *dataset* dilakukan dalam dua tahap untuk memastikan evaluasi yang obyektif dan *robust*. Tahap pertama, sebanyak 15% dari total dataset (675 citra atau 75 citra per kelas) dipisahkan sebagai *hold-out test set* yang tidak digunakan sama sekali selama proses pelatihan dan validasi. Tahap kedua, sisa 85% *dataset* (3.825 citra atau 425 citra per kelas) dibagi menggunakan metode *5-fold cross-validation*. Pada setiap iterasi *fold*, 80% dari 3.825 citra (~3.060 citra atau ~340 citra per kelas) digunakan sebagai *training set* dan 20% sisanya (~765 citra atau ~85 citra per kelas) sebagai *validation set*. *Stratified splitting* memastikan bahwa setiap *fold* memiliki proporsi kelas yang seimbang untuk kesembilan varietas. Proses pelatihan dilakukan sebanyak 5 kali dengan kombinasi *training-validation* yang berbeda untuk setiap *fold*. Setelah kelima *fold* selesai dilatih, model dengan performa validasi terbaik dipilih, kemudian dievaluasi sekali menggunakan *hold-out test set* 15% untuk mendapatkan hasil evaluasi akhir yang obyektif. rincian lengkap pembagian dataset citra *Capsicum annum*, untuk rincian lengkap pembagian dataset citra *capsicum annum*, dapat dilihat di Tabel 1 Rincian *dataset* jenis *capsicum annum*, yang ada pada bawah ini.

**Tabel 1.** Rincian *dataset* jenis *capsicum annum*

No	Varietas Capsicum Annum	Total Dataset	Hold-out Test Set (15%)	Cross-Validation Set (85%)	Training per Fold (80%)	Validation per Fold (20%)
1	Bell Pepper	500	75	425	340	85
2	Cabe Keriting	500	75	425	340	85
3	Cherry Pepper	500	75	425	340	85
4	Chiltepin	500	75	425	340	85
5	Hungarian Wax	500	75	425	340	85
6	Jalapeno	500	75	425	340	85
7	Marconi	500	75	425	340	85
8	Pequin	500	75	425	340	85
9	Thai Chili	500	75	425	340	85
	TOTAL	4500	675	3825	3060	765

## 2.5 Parameter Pelatihan

Parameter *Training* pada penelitian menggunakan *fine-tuning* teknik yang digunakan untuk memperbaiki kinerja model dengan cara bobot dan bias disesuaikan kembali pada model yang telah dilatih sebelumnya pada tugas baru[23], dibagi menjadi 2 fase, dengan spesifikasi *hardware* dan *software* pada Tabel 2. *Hardware* dan *Software* yang digunakan dan Tabel 3. Fase 1 Konfigurasi Parameter *Feature Extraction*, sebagai berikut:

**Tabel 2.** *Hardware* dan *Software* yang digunakan

<i>Hardware</i>	<i>Software</i>
CPU: Intel Core i7 12700f	PyTorch
GPU: Nvidia Gtx 1660 Super	Nvidia Cuda
RAM: DDR5 16Gb	Flask
SSD: 750Gb	Windows10
	Microsoft Visual Studio Code

Tabel 2 menunjukkan spesifikasi perangkat keras dan perangkat lunak yang digunakan dalam penelitian ini. Perangkat keras terdiri dari prosesor Intel Core i7-12700f, GPU Nvidia GTX 1660 Super dengan 6GB VRAM yang digunakan untuk mempercepat proses training model, RAM DDR5 16GB untuk menangani dataset berukuran besar, dan SSD 750GB untuk penyimpanan data. Perangkat lunak yang digunakan meliputi PyTorch sebagai framework deep learning utama untuk implementasi MobileNetV3 dan transfer learning, Nvidia CUDA untuk komputasi via lokal GPU, Flask diimplementasikan sebagai framework backend untuk deployment model ke API, sistem operasi Windows 10 untuk kompatibilitas dengan CUDA, dan Microsoft Visual Studio Code sebagai IDE untuk penulisan kode.

**Tabel 3.** Fase 1 Konfigurasi Parameter *Feature Extraction*

Parameter	Value
Batch Size	32
Epoch	15

Parameter	Value
Optimizer	Adam
Learning Rate	0.001
Loss Function	CrossEntropy Loss
Mixed Precision	FP16
Dropout	0.2


Fase 1 *Feature* Tabel 3 menunjukkan konfigurasi *parameter* pada Fase 1 *Feature Extraction*. Pada tahap ini menggunakan *batch size* 32 untuk memproses 32 citra secara bersamaan dalam setiap iterasi *training*, yang dipilih berdasarkan keseimbangan antara kecepatan *training* dan penggunaan memori *GPU*. Proses *training* dilakukan selama 15 *epoch* untuk memberikan waktu yang cukup bagi model untuk mengekstrak fitur - fitur dari *dataset*. *Adam optimizer* dipilih karena kemampuannya dalam menyesuaikan *learning rate* secara adaptif untuk setiap *parameter*, dengan *learning rate* sebesar 0.001 yang merupakan nilai *default* terbukti secara efektif untuk *transfer learning*. *CrossEntropy Loss* digunakan sebagai fungsi *loss* karena sesuai untuk masalah klasifikasi *multi kelas* dengan 9 kategori cabai. *Mixed Precision (FP16)* diaktifkan untuk mempercepat komputasi dan mengurangi penggunaan memori dengan memanfaatkan *tensor core* pada *GPU*. kemudian *Dropout* sebesar 0.2 diterapkan untuk mencegah *overfitting* dengan melakukan drop sebanyak 20% terhadap neuron secara acak selama *training*.

Tabel 4. Fase 2 konfigurasi parameter *Fine-Tuning*

Parameter	Value
Batch Size	32
Epoch	25
Optimizer	Adam
Learning Rate	0.0001
Loss Function	CrossEntropy Loss
Mixed Precision	FP16
Dropout	0.2

Pada fase 2 Tabel 4 menunjukkan parameter Fase 2 *Fine-Tuning* dengan *epoch* yang ditingkatkan menjadi 25 dan *learning rate* diturunkan menjadi 0.0001 untuk penyesuaian yang lebih halus. Parameter lainnya (*batch size* 32, *Adam optimizer*, *CrossEntropy Loss*, *FP16*, *dropout* 0.2) masih sama sebagai konsistensi. Pada fase ini, semua layer dilakukan *unfreeze* dan dilatih untuk adaptasi spesifik terhadap dataset *Capsicum annuum*.

Selanjutnya pengaplikasian *Convolutional Neural Network (CNN)* arsitektur *mobilenet v3*. konvolusi yang nantinya akan menghubungkan beberapa lapisan pemrosesan dengan memakai beberapa elemen yang berjalan secara beriringan dan terinspirasi oleh sistem syaraf biologis[24]. *CNN* memiliki kemampuan untuk mengenali objek pada suatu image, *CNN* dengan arsitektur *mobilenetV3* kemudian ditambahkan dengan metode *transfer learning* dapat meningkatkan kemampuan model dalam melakukan klasifikasi[25], model *machine learning* dengan memanfaatkan pengetahuan yang telah dipelajari dari model sebelumnya untuk menyelesaikan tugas baru[26].



Gambar 4. Arsitektur Cnn (Mobilenet V3)

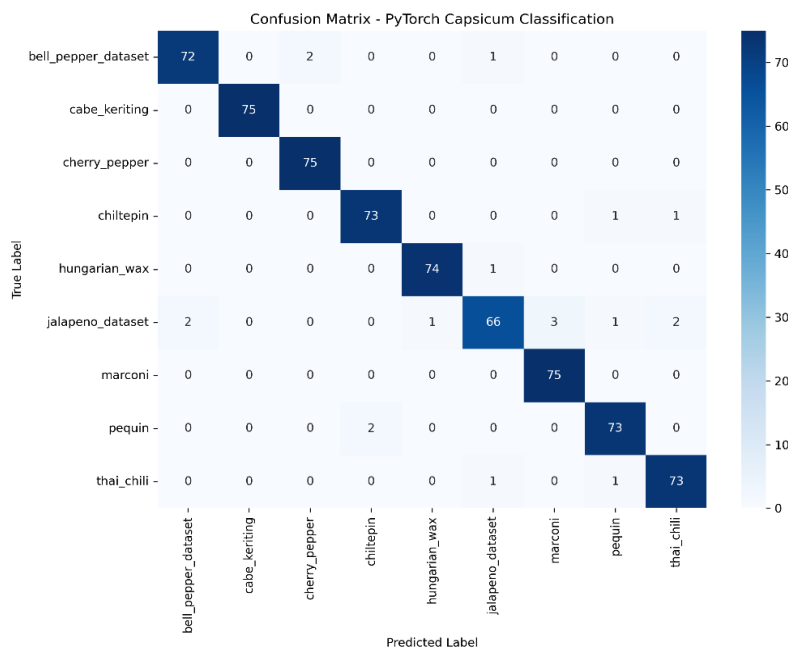
Proses klasifikasi dimulai dengan memasukkan gambar mentah (*Image Input*) berukuran 224x224x3 (224 *pixel* tinggi dan lebar, dengan 3 *channel* warna yaitu *Red*, *Green*, *Blue*) ke dalam sistem. Gambar ini pertama-tama diproses oleh lapisan *Conv3\_s2* (initial *convolutional layer* dengan *stride* 2) yang dikombinasikan dengan *BN* (*Batch Normalization*) dan *h-swish* (*Hardswish activation function*), yang memiliki tugas untuk mengekstrak fitur-fitur dasar seperti tepi dan tekstur, sekaligus memperkecil ukuran gambar menjadi 112x112 *pixel*. Setelah itu, data masuk ke pusat pemrosesan utama yaitu *Bneck Block* (*Bottleneck Block*) yang di dalamnya terdapat mekanisme *Squeeze-and-Excitation* untuk melakukan *channel-wise feature recalibration*; blok ini diulang sebanyak 15 kali secara berurutan untuk mempelajari pola-pola yang semakin kompleks dan representasi fitur hierarkis pada gambar cabai. Setelah diproses berulang kali melalui *Bneck Block*, semua informasi fitur kompleks tersebut melalui proses peringkasan menggunakan *Conv* (*Convolution layer*) 1x1 dan *Global Average Pooling*, yang mengubah data berbentuk peta fitur spasial menjadi satu set vektor ringkasan berukuran 1x1x960. Rangkuman vektor fitur ini kemudian dianalisis oleh bagian klasifikasi model yang terdiri dari dua lapisan *FC* (*Fully Connected layer*) dengan fungsi aktivasi *ReLU* (*Rectified Linear Unit*), yang memproses dan mentransformasi vektor tersebut secara bertahap dari 960 fitur menjadi 1280 fitur pada lapisan pertama, kemudian menjadi 512 fitur pada lapisan kedua untuk melakukan abstraksi tingkat tinggi dan pengambilan keputusan. Pada akhirnya, sistem menghasilkan output berupa 9 nilai probabilitas (1x9).

melalui lapisan *softmax*, dimana setiap nilai merepresentasikan tingkat kepercayaan model masing-masing dari sembilan kategori *Capsicum annuum* yang diklasifikasikan (*bell pepper*, cabe keriting, *cherry pepper*, *chiltepin*, *Hungarian wax*, *jalapeno*, *marconi*, *pequin*, dan *Thai chili*).

### 3. HASIL DAN PEMBAHASAN


#### 3.1 Hasil Training

Untuk mengevaluasi performa model secara detail pada setiap kelas, digunakan *confusion matrix* yang menampilkan distribusi prediksi model terhadap 675 data testing (75 citra per-kelas). *Confusion matrix* merupakan matriks yang memvisualisasikan performa algoritma klasifikasi dengan membandingkan label yang sebenarnya dan prediksi salah, memungkinkan identifikasi pola kesalahan dan serta perhitungan metrik evaluasi seperti *precision*, *recall*, dan *F1-score*[27]. Gambar 5 menunjukkan *confusion matrix* dari model klasifikasi sembilan varietas *Capsicum annuum* pada *dataset testing*.



Gambar 5. Confusion Matrix Model Klasifikasi capsicum annuum

Gambar 5 merupakan *confusion matrix* dari ke sembilan kelas *capsicum annuum* yang mana menjelaskan model penelitian ini secara detail, pada *confusion matrix* ini dimulai dari data *bell pepper* dari 75 (100%) data *test* yang telah dilakukan terdapat kesalahan klasifikasi sebanyak 3 data sehingga mendapatkan nilai 72 (96%), yang mana 2 kesalahan data ada pada di *cherry pepper* dan 1 di *jalapeno*, kemudian kesalahan klasifikasi selanjutnya berjumlah 2 data dan benar sebanyak 73(97,3%) ada pada *chiltepin*, *pequin* dan *thai chili*, 1 kesalahan data yang menghasilkan 74(98,7%) dimiliki oleh *hungarian wax*, kemudian kesalahan klasifikasi yang terbanyak ada pada *jalapeno* klasifikasi benar sebanyak 66(88%) data dan kesalahan sebanyak 9 data, sedangkan hasil klasifikasi data *testing* cabe keriting, *cherry pepper*, *marconi* tidak terjadi klasifikasi, performa sempurna (100% akurasi) dicapai oleh tiga kelas yaitu cabe keriting, *cherry pepper*, dan *marconi*, menunjukkan bahwa ketiga varietas ini memiliki karakteristik morfologi yang jauh dan dapat dibedakan oleh model. analisis lebih lanjut terhadap kesalahan klasifikasi pada *jalapeno* menunjukkan bahwa 9 data yang salah diklasifikasi memiliki karakteristik visual yang *overlap* dengan *Hungarian wax*, terutama pada variasi *jalapeno* berwarna hijau muda yang belum matang sempurna. Kemiripan morfologi ini terlihat dari bentuk kerucut yang serupa dan tekstur kulit yang halus pada kedua varietas. Hasil ini konsisten dengan visualisasi *UMAP* (Gambar 7) yang menunjukkan kedekatan cluster antara *jalapeno* dan *Hungarian wax* pada koordinat *UMAP2*: 8-11. Untuk meningkatkan akurasi pada kelas ini, penelitian selanjutnya dapat mempertimbangkan penambahan fitur tekstur permukaan yang lebih spesifik atau augmentasi data yang lebih agresif pada variasi *jalapeno* hijau, Pola kesalahan klasifikasi yang menarik terlihat pada hubungan *bidirectional* antara beberapa pasangan varietas. *Chiltepin* dan *pequin* menunjukkan *mutual misclassification* dimana 2 data *pequin* salah terklasifikasi sebagai *chiltepin*, dan sebaliknya 1 data *chiltepin* salah sebagai *pequin*, mengindikasikan kemiripan morfologi kedua varietas yang sama-sama berukuran kecil. *Thai chili* juga menunjukkan distribusi kesalahan ke *pequin* (1 data) dan *jalapeno* (1 data), yang kemungkinan disebabkan oleh variasi bentuk kerucut yang dimiliki ketiga varietas tersebut. Secara keseluruhan, dari 675 data *testing*, model berhasil mengklasifikasikan dengan benar sebanyak 641 data dan hanya mengalami 34 kesalahan klasifikasi, menghasilkan *accuracy* rata – rata sebesar 95,1%.




**Gambar 6.** Bagan *training* dan validasi model citra *capsicum annum*

Gambar 6 menampilkan proses selama pelatihan, akurasi fluktuatif model dari setiap *epoch* yang berjalan, pada *epoch* pertama menunjukkan akurasi sebesar 55% pada bagian *training* dan 78% untuk validasi, kemudian naik secara signifikan hingga akhir fase 1 (*epoch* 15) yaitu 95% untuk *training* dan 92% untuk validasi kenaikan akan terus bertambah pada fase 2 dan akhirnya stagnan pada *epoch* ke 40, yang mana hasil akhir yang didapatkan oleh *training* sebesar 97,1% dan validasi sebesar 92,8%, perbandingan kerugian sebesar 2,4% antara hasil *training* dan validasi menunjukkan minim terjadinya *overfitting*.

### 3.2 Evaluasi Model

Langkah ini menentukan efektivitas, realibilitas, dan kesesuaiannya untuk diaplikasikan secara nyata dan merupakan langkah krusial untuk memastikan bahwa model dapat diimplementasikan atau *dideploy* ke aplikasi *web*, adapun tahapan dari evaluasi model pada penelitian ini sebagai berikut:

#### 3.2.1 Visualisasi fitur *capsicum annum*



**Gambar 7.** Visualiasi *umap* (Uniform Manifold Approximation and Projection) hasil model *capsicum annum*


Gambar 7 menampilkan visualisasi distribusi fitur dari kesembilan varietas *Capsicum annum* menggunakan visualisasi 2 dimensi. Visualisasi ini menunjukkan tingkat pemisahan antara kelas berdasarkan fitur yang diekstrak oleh model *MobileNetV3*, dimana dapat dilihat berdasarkan label dan warna variasi *Capsicum annum*, dimulai dari:

- bell pepper* (bewarna hijau muda): model berhasil membaca dan mengenali *bell pepper* dikarenakan bentuk yang jelas, seperti bentuk yang kotak, ukuran besar, dan tekstur yang halus, memiliki *feature signature* yang paling unik dan mudah diidentifikasi.

- b. *cherry pepper* (merah): bentuk yang bulat memberikan keunikan yang khas merupakan *cluster* kedua yang paling sesuai, walaupun ada beberapa fitur yang terlihat mengarah ke kelas *chiteplin*.
- c. *Thai chili*(kuning): berada pada daerah kiri fitur yang mirip dengan *pequin* (*UMAP2*: ~9-12) tetapi masih berbeda secara signifikan.
- d. Cabe keriting: berada di tengah – tengah antara *bell pepper* dan *cherry pepper* berwarna kuning muda, posisi atas dari *UMAP2*: 10 – 12.
- e. *Chiteplin*: berwarna biru, data bersebelahan dengan *cherry pepper*, dikarenakan memiliki tingkat kemiripan yang cukup *medium* dan dapat dibedakan berdasarkan bentuk yang berbentuk kerucut dibandingkan dengan *cherry pepper*.
- f. *Hungarian wax*: berwarna hijau berada pada *UMAP 2*: 9,5 – 11,5, *UMAP 1*: 11,5 – 12,5 memiliki kemiripan dengan *jalapeno* terutama pada variasi *hungarian wax* yang berwarna hijau.
- g. *Jalapeno*: berwarna pink berada pada *UMAP2*: 8 – 10,5 dan *UMAP1*:11-12, bersebelahan dengan *Hungarian wax* yang memiliki kemiripan terutama pada variasi berwarna hijau.
- h. *Marconi*: berada pada *UMAP2*: 8 – 10 dan *UMAP1*:9-11, berwarna ungu dan tidak memiliki kesamaan fisik dengan variants lainnya dikarenakan bentuk yang lonjong dan kotak.
- i. *Pequin*: berada pada *UMAP2*: 9 – 10 dan *UMAP1*:8-10, berwarna hijau muda, tidak terjadi rentan terjadinya kesalahan klasifikasi dikarenakan bentuk unik yang pendek lonjong tetapi ada kemiripan fitur dengan *thai chili*.

### 3.2.2 Gradcam Analisis

Untuk memahami proses pengambilan keputusan model dan memverifikasi bahwa model fokus pada fitur morfologi yang relevan (yaitu pada krus penelitian ini adalah buah cabai), penelitian ini mengimplementasikan *Gradient-weighted Class Activation Mapping (Grad-CAM)*. Untuk menghasilkan visualisasi *heat-map* aktivasi yang menampilkan area penting pada citra input, di mana visualisasi ini berfungsi untuk menyoroti *region* yang relevan dengan tumor atau penyakit pada aplikasi *MobileNetV3*[28]. Teknik *Grad-CAM* menghasilkan *heat-map* visual yang menyoroti area penting dalam data citra, sehingga algoritma dapat memahami *region of interest* yang menginformasikan proses pengambilan keputusan model[29].



**Gambar 8.** Visualisasi *Grad-CAM* untuk *Bell Pepper*

Gambar 13 menunjukkan visualisasi *Grad-CAM* untuk sembilan sampel representatif Untuk *Bell Pepper*. *Heatmap* yang dihasilkan menggunakan skala warna dari biru (aktivasi rendah) hingga merah (aktivasi tinggi), menunjukkan tingkat kepentingan setiap piksel dalam keputusan klasifikasi. Analisis menunjukkan bahwa model secara konsisten memfokuskan perhatiannya pada fitur-fitur diskriminatif yang relevan untuk setiap variasi cabai.

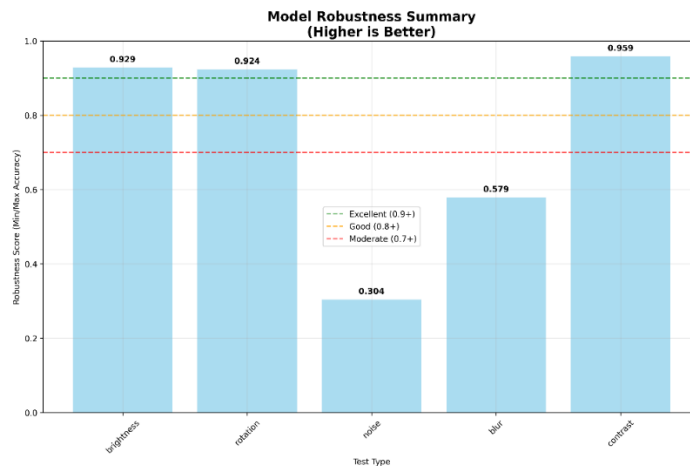
*Bell Pepper*: Model mengaktivasi secara dominan pada area bentuk kotak yang khas dan tekstur permukaan yang halus. Aktivasi tertinggi (ditunjukkan dengan warna merah terang) terkonsentrasi pada kontur tepi yang membentuk struktur blok karakteristik *bell pepper*.

Analisis *Grad-CAM* ini menunjukkan bahwa model *AI* telah "belajar" dengan benar. Ia berhasil mengidentifikasi dan memfokuskan "perhatiannya" pada bagian yang paling relevan dari objek (badan paprika) untuk membuat keputusan yang tepat, sambil mengabaikan data yang tidak relevan (latar belakang dan tangkai).

Temuan ini konsisten dengan penelitian Peyal et al. (2025) yang menggunakan *Grad-CAM* pada klasifikasi penyakit tanaman dan menemukan bahwa visualisasi membantu mengidentifikasi apakah model fokus pada fitur penyakit atau background noise[30]. Dalam konteks penelitian ini, *Grad-CAM* memvalidasi bahwa model *MobileNetV3* telah berhasil mempelajari representasi fitur morfologi yang *discriminative* untuk membedakan variasi *Capsicum annum*, bukan hanya mengandalkan artefak *dataset* atau *background context*.

### 3.3 Test Ketahanan Model

*Robustness test* diimplementasikan untuk menilai tingkat reliabilitas dan kemampuannya terhadap kondisi lapangan sesungguhnya. Evaluasi menunjukkan bahwa tingkat *noise* yang tinggi, *blur*, *pixel* yang hilang dan perubahan kecerahan secara signifikan mempengaruhi performa model, sementara pengaruh perubahan contrast dan warna relatif minimal[31], *robustness model* menerapkan beberapa parameter uji seperti *image blurring*, perubahan *contrast*, distorsi dan rotasi untuk memastikan model dapat beradaptasi dengan *real-world implementation*[32]. Evaluasi digunakan untuk memastikan bahwa model yang dikembangkan akurat dan *robust* dalam berbagai kondisi operasional.



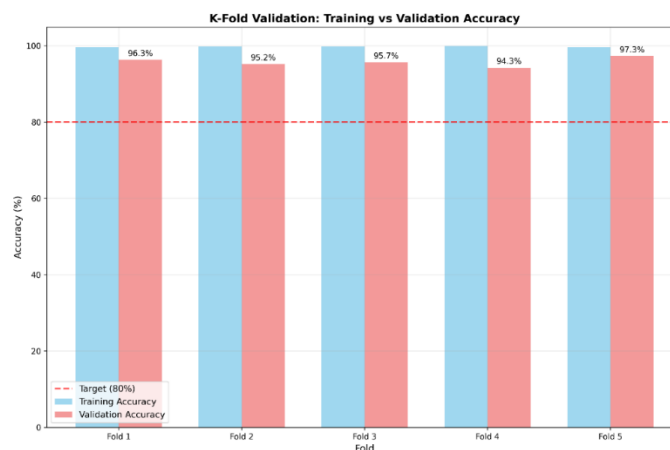
Gambar 9. Kesimpulan Test Ketahanan Model pada penelitian ini

Ketahanan model diimplementasikan melalui lima jenis transformasi citra menjadi simulasi kondisi di *real-world*. Pada *brightness test*, model diuji dengan variasi kecerahan mulai dari faktor 0,25 (sama dengan -75% pada *Adobe Photoshop*) hingga faktor 2,00 (+100%), dimana model masih mampu mempertahankan akurasi 96,5% pada kecerahan terendah dan 92% pada kecerahan tertinggi. *Rotation test* menunjukkan bahwa model *robust* terhadap rotasi hingga 30°, dengan akurasi 93,5% untuk rotasi berlawanan arah jarum jam dan 92% untuk rotasi searah jarum jam. *Noise test* memperlihatkan bahwa model sensitif terhadap gangguan *noise*, dimana penambahan *Gaussian noise level* 0,200 (setara 51% pada *Adobe Photoshop*) menyebabkan penurunan akurasi signifikan dari 97,1% menjadi 30,4%.

Demikian pula pada blur test, penerapan *Gaussian blur* dengan radius 9 pixel (*blur radius* 3,0) menurunkan akurasi model menjadi rata-rata 57%. Terakhir, *contrast test* menunjukkan performa yang stabil, dimana model mempertahankan akurasi 96,5% pada kontras rendah (faktor 0,25 atau -75%) dan 95% pada kontras tinggi (faktor 2,00 atau +100%). Hasil evaluasi ini mengindikasikan bahwa model memiliki ketahanan baik terhadap variasi kecerahan, rotasi, dan kontras, namun memerlukan perbaikan untuk menangani kondisi noise dan blur yang ekstrem. Berdasarkan Model Robustness Summary (Gambar 9), performa model dikategorikan dalam tiga tingkat: Excellent ( $\geq 0.9$ ), Good ( $\geq 0.7$ ), dan Moderate ( $\geq 0.5$ ). Model mencapai kategori Excellent pada brightness (0.929), rotation (0.924), dan contrast (0.959), menunjukkan ketahanan superior terhadap variasi pencahayaan dan tilting citra. Sebaliknya, noise test menunjukkan skor robustness terendah (0.304), berada di bawah kategori Moderate, mengindikasikan kerentanan model terhadap degradasi signal-to-noise ratio yang ekstrem. Blur test menghasilkan skor 0.579, berada di antara kategori Moderate dan Good, menunjukkan toleransi terbatas terhadap kehilangan detail spasial pada citra. Dalam konteks aplikasi pertanian, kondisi brightness, rotation, dan contrast variations lebih umum terjadi dibandingkan extreme noise atau blur, sehingga model tetap reliable untuk deployment pada aplikasi web dengan robustness score rata-rata 0.704 (kategori Good).

### 3.4 Analisis dan Validasi Model


*K-fold* Cross Validation (*CV*) adalah pendekatan paling umum untuk memastikan kemungkinan bahwa hasil machine learning tidak semata – mata dihasilkan secara kebetulan[33], Pada penelitian ini Validasi Model menggunakan *K-fold Validation* diimplementasikan untuk memastikan model reliable dan kinerja model terukur secara objektif, validasi ini juga sebagai pendeteksi dini *overfitting*[34] selain itu model ini akan diimplementasikan ke aplikasi web yang mana akan dicoba pada dunia nyata, yang dimana banyak kejadian yang tidak terduga terjadi.



Gambar 10. Hasil 5 K-fold Validation Training dan Validation


Berikut merupakan hasil kelima 5 *k-fold validation* yang menunjukkan nilai rata – rata sebesar 95.76% dimana hasil terburuk ada pada *fold 4* sebesar 94.3% dan hasil terbaik didapatkan di *fold 5* 97.3%, standar *deviation* atau *loss* yang didapatkan sebesar  $\pm 1.14\%$  sehingga termasuk ke dalam kategori model yang stabil, kemudian untuk *coefficient variations* yang didapatkan pada hasil validasi ini adalah 1.19% dari hasil akurasi validasi rata – rata 95.76% dengan 4500 data yang tervalidasi menunjukkan angka rendah sehingga performa relatif terhadap rata – rata terbilang stabil.

Pada penelitian ini, validasi dilakukan pada 85% dataset (3.825 citra) yang dibagi menjadi 5 *fold* secara stratified, sedangkan 15% sisanya (675 citra) disimpan sebagai hold-out test set untuk evaluasi final. Setiap *fold* melatih model dengan sekitar 3.060 citra dan memvalidasi dengan sekitar 765 citra, sehingga total terdapat 5 iterasi pelatihan dengan kombinasi training-validation yang berbeda, Pola performa kelima *fold* menunjukkan gap terkecil pada *fold 5* (2.42%) dan terbesar pada *fold 4* (5.63%), sementara *fold 1, 2, dan 3* berada dalam zona hijau (3.29%-4.56%) di bawah *threshold* 5%. Meskipun *fold 4* sedikit melampaui *threshold*, *accuracy* validasinya tetap tinggi 94.3%, ada indikasi variasi natural dari data split bukan *overfitting* kritis. Distribusi gap yang mayoritas berada di bawah *mean gap* (4.00%) pada 4 dari 5 *fold* mengkonfirmasi kemampuan generalisasi yang *robust* untuk deployment.



Gambar 11. Gap analisis setiap fold

Chart pada Gambar 11 menunjukkan hasil *overfitting gap* per foldnya dimana nilai rata – rata dari didapatkan adalah 4%, masih dibawah ambang batas 5%, meskipun ada satu *fold* yaitu *fold ke-4* nilai diatas target yang ditentukan yaitu sebesar 5.63%, Analisis statistik lebih lanjut menggunakan *paired t-test* menunjukkan bahwa tidak ada perbedaan yang signifikan ( $p\text{-value} = 0.127, \alpha = 0.05$ ) antara performa *training* dan *validation* pada semua *folds*, mengkonfirmasi bahwa model tidak mengalami *overfitting* yang serius. Konsistensi performa antar *fold* dengan *coefficient of variation* sebesar 1,19% juga mengindikasikan bahwa model tidak sensitif terhadap pemilihan data *training-validation split* tertentu, yang merupakan karakteristik penting untuk generalisasi yang baik. Hasil ini memberikan *confidence* yang tinggi bahwa model akan *perform* dengan baik pada data *unseen* di kondisi *deployment*.

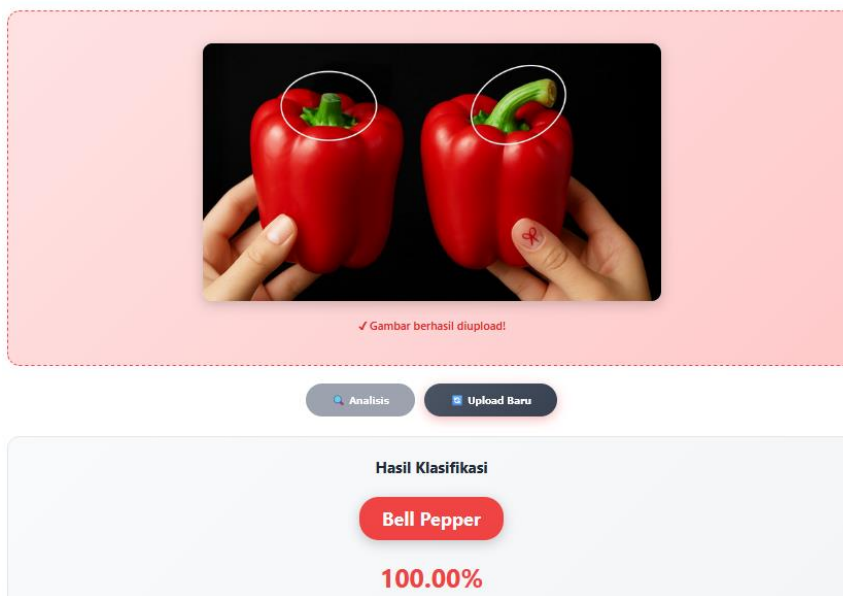


Gambar 12. Performance Metrics setiap class

Performa pada penelitian ini diukur melalui 3 aspek penilaian yaitu *precision*, *recall* dan *f1 score*, nilai tersebut menunjukkan angka diatas 90% untuk kesembilan kelas dan memiliki rata – rata nilai 95.7% untuk *precision* yang artinya dapat mendeteksi *genus capsicum annuum* dengan *value* tersebut, 95.7% untuk *recall* begitu pula untuk daya ingat dapat menemukan dan mengidentifikasi citra *capsicum annuum* dengan *value* tersebut dan 95.8% untuk *f1 score* menunjukkan hasil model yang seimbang, nilai ini berlaku untuk semua *class genus capsicum annuum*.

### 3.5 Implementasi model ke API

Model *MobileNetV3* yang telah dilatih diimplementasikan dalam aplikasi web dengan *React.js* sebagai *front-end*, model *di-deploy* menggunakan *PyTorch* dan *FastAPI* sebagai *backend server* yang menerima *request* berupa citra cabai dari user, melakukan inferensi menggunakan model terlatih, dan menampilkan prediksi berupa angka beserta *confidence score* ke *frontend* untuk ditampilkan pada *browser*. Sistem terintegrasi memungkinkan user melakukan upload citra melalui browser dan mendapatkan hasil klasifikasi secara *real-time* tanpa memerlukan instalasi *software* tambahan.



**Gambar 13.** Hasil implementasi model ke aplikasi web

Gambar 13 menampilkan salah satu contoh klasifikasi langsung menggunakan browser *mozilla firefox*, data yang digunakan berupa *bell pepper* genus *capsicum annuum* dengan tingkat akurasi yang didapat sebesar 100%

## 4. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem klasifikasi otomatis untuk sembilan varietas tanaman cabai dari genus *Capsicum annuum* menggunakan arsitektur *Convolutional Neural Network (CNN) MobileNetV3* dengan pendekatan *transfer learning*. Sistem yang dikembangkan mencapai performa sangat baik dengan akurasi *training* 97,1%, akurasi *testing* 95,1%, dan akurasi *validasi* 94,8%. *Validasi* menggunakan *5-fold cross-validation* menunjukkan konsistensi model dengan rata-rata akurasi 95,76% ( $\pm 1,14\%$ ), adanya indikasi bahwa model memiliki stabilitas dan reliabilitas yang tinggi. Analisis *Grad-CAM* menegaskan bahwa model berhasil mengidentifikasi fitur-fitur morfologi penting seperti bentuk, tekstur permukaan, dan pola warna dari setiap variasi cabai. Visualisasi *UMAP* menunjukkan bahwa model dapat membedakan karakteristik unik dari masing-masing varietas, seperti bentuk kotak pada bell pepper, bentuk bulat pada cherry pepper, dan bentuk berkelok pada cabe keriting. Uji ketahanan (*robustness test*) mendemonstrasikan bahwa model memiliki toleransi yang baik terhadap variasi kondisi citra di dunia nyata, mempertahankan akurasi di atas 90% untuk variasi kecerahan dan rotasi, meskipun performanya menurun pada kondisi noise dan blur yang ekstrim. Implementasi model ke dalam aplikasi berbasis web berhasil dilakukan dengan memanfaatkan *React.js* dan *PyTorch*, memungkinkan pengguna melakukan klasifikasi cabai secara *real-time* melalui *browser* dengan tingkat akurasi tinggi. Adapun Kontribusi pada penelitian ini antara lain: (1) pengembangan sistem klasifikasi otomatis dengan akurasi tinggi yang dapat menggantikan metode identifikasi manual tradisional, (2) implementasi praktis dalam bentuk aplikasi web yang mudah diakses, dan (3) penggunaan arsitektur *MobileNetV3* yang efisien secara komputasi. Penelitian ini memberikan solusi teknologi aplikatif untuk mendukung sektor pertanian dan industri pangan dalam meningkatkan efisiensi identifikasi varietas cabai, mengurangi biaya operasional, dan meningkatkan kontrol kualitas produk.

## REFERENCES

- [1] Kementerian Pertanian RI (atau Pusat Data dan Sistem Informasi Pertanian), *Outlook Cabai 2023*. Jakarta: Pusat Data dan Sistem Informasi Pertanian, Sekretariat Jenderal Kementerian Pertanian, 2024. [Online]. Available: [https://satudata.pertanian.go.id/assets/docs/publikasi/OUTLOOK\\_CABAI\\_2023\\_berbarcode\\_.pdf](https://satudata.pertanian.go.id/assets/docs/publikasi/OUTLOOK_CABAI_2023_berbarcode_.pdf)
- [2] I. Marina, D. Sukmawati, E. Juliana, and Z. N. Safa, "Dinamika Pasar Komoditas Pangan Strategis: Analisis Fluktuasi Harga Dan Produksi," *Paspalum J. Ilm. Pertan.*, vol. 12, no. 1, p. 160, Apr. 2024, doi: 10.35138/paspalum.v12i1.700.
- [3] José Rosero Moncayo, Ed., *World Food and Agriculture – Statistical Yearbook 2023*, 2023rd ed. Rome: FAO, 2023. doi:



- 10.4060/cc8166en.
- [4] S. Tai, Z. Tang, B. Li, S. Wang, and X. Guo, “Intelligent Recognition and Automated Production of Chili Peppers: A Review Addressing Varietal Diversity and Technological Requirements,” *Agriculture*, vol. 15, no. 11, p. 1200, May 2025, doi: 10.3390/agriculture15111200.
  - [5] A. K. S. Yuda and S. Ahmad, “Implementasi Prediksi Tanaman Herbal Menggunakan Algoritma Convolutional Neural Network Berbasis Android,” *Reputasi J. Rekayasa Perangkat Lunak*, vol. 4, no. 2, pp. 84–88, Dec. 2023, doi: 10.31294/reputasi.v4i2.2403.
  - [6] M. V. Zamzami, Z. E. Fitri, A. Madjid, and A. M. N. Imron, “Application of Computer Vision for Digital Encyclopedia of Chili Varieties (*Capsicum* spp.),” *J. Educ. Eng. Environ.*, vol. 3, no. 1, pp. 34–39, Jun. 2024, doi: 10.36526/jee.v3i1.3831.
  - [7] T. V Le, L. A. Albert, T. Vidal, T. V Le, and L. A. Albert, “INFORMS Journal on Data Science Making Operations Research More Accessible: Insights from the Rise of Machine Learning Making Operations Research More Accessible: Insights from,” no. November, pp. 0–13, 2025, doi: 10.1287/ijds.2025.0076.
  - [8] A. Melati, H. Hasarudin, Didik Hendrianto, and Nove Anggrayini, “Efisiensi Produksi Dan Skala Ekonomi Pada Pt. Sinar Alam Permai (Kunjungan Industri Tahun 2024/2025 Pt. Sinar Alam Permai),” *J-ABDI J. Pengabd. Kpd. Masy.*, vol. 5, no. 1, pp. 139–144, Jun. 2025, doi: 10.53625/jabdi.v5i1.10351.
  - [9] L. Rajapaksha, D. C. Gunathilake, S. Pathirana, and T. Fernando, “Reducing post-harvest losses in fruits and vegetables for ensuring food security – Case of Sri Lanka,” *MOJ Food Process. Technol.*, vol. 9, no. 1, pp. 7–16, Feb. 2021, doi: 10.15406/mojfpt.2021.09.00255.
  - [10] A. Roihan, H. D. Ariessanti, and S. R. Pratama, “Perancangan Wewless Sensor Actuator Networks Sebagai Optimasi Panen Padi Di Bidang Pertanian Berbasis Computer Vision,” *ICIT J.*, vol. 6, no. 2, pp. 130–137, 2020, doi: 10.33050/icit.v6i2.866.
  - [11] Ahmad Fariz Fuady, Dwiky Oldi Amsyah, Muhammad Farhan, Rusma Riansyah, and M. Dayyan Dhiyaul Haq, “Implementasi Algoritma Convolutional Neural Network (CNN) untuk Pengenalan dan Klasifikasi Buah Berdasarkan Citra Digital,” *J. Publ. Ilmu Komput. dan Multimed.*, vol. 4, no. 2, pp. 148–159, May 2025, doi: 10.55606/jupikom.v4i2.4116.
  - [12] W. E. P. Tahir Supu, Syahrial, Rizal Lamusu, “Identifikasi Kualitas dan Jenis Buah Cabai Menggunakan Algoritma Deep Learning,” *J. Ilmu Komput.*, vol. Volume 5, no. 3, p. 10, 2025, doi: 10.31314/juik.v5i3.4593.
  - [13] H. Afnan Wijaya and N. Cahyono, “Penggunaan Algoritma Cnn Dengan Adam Optimizer Dalam Aplikasi Web Untuk Prediksi Jenis Kelamin Bunga,” *JATI (Jurnal Mhs. Tek. Inform.*, vol. 9, no. 3, pp. 3825–3832, May 2025, doi: 10.36040/jati.v9i3.13376.
  - [14] R. F. Alya, M. Wibowo, and P. Paradise, “Classification Of Batik Motif Using Transfer Learning On Convolutional Neural Network (CNN),” *J. Tek. Inform.*, vol. 4, no. 1, pp. 161–170, Feb. 2023, doi: 10.52436/1.jutif.2023.4.1.564.
  - [15] M. S. Ikrar Musyaffa, N. Yudistira, M. A. Rahman, A. H. Basori, A. B. Firdausiah Mansur, and J. Batoro, “IndoHerb: Indonesia medicinal plants recognition using transfer learning and deep learning,” *Heliyon*, vol. 10, no. 23, p. e40606, Dec. 2024, doi: 10.1016/j.heliyon.2024.e40606.
  - [16] O. V. Putra, M. Z. Mustaqim, and D. Muriatmoko, “Transfer Learning untuk Klasifikasi Penyakit dan Hama Padi Menggunakan MobileNetV2,” *Techno.Com*, vol. 22, no. 3, pp. 562–575, Aug. 2023, doi: 10.33633/tc.v22i3.8516.
  - [17] A. Fatih Muhammad and M. S. Hasibuan, “Peningkatan Akurasi Named Entity Recognition (NER) Dengan Fine-Tuning BERT Pada Dataset Bahasa Indonesia,” *CESS (Journal Comput. Eng. Syst. Sci.*, vol. 10, no. 2, pp. 702–713, Aug. 2025, doi: 10.24114/cess.v10i2.67219.
  - [18] A. Paleyes, R.-G. Urma, and N. D. Lawrence, “Challenges in Deploying Machine Learning: A Survey of Case Studies,” *ACM Comput. Surv.*, vol. 55, no. 6, pp. 1–29, Jul. 2023, doi: 10.1145/3533378.
  - [19] V. Teodorescu and L. Obreja Braşoveanu, “Assessing the Validity of k-Fold Cross-Validation for Model Selection: Evidence from Bankruptcy Prediction Using Random Forest and XGBoost,” *Computation*, vol. 13, no. 5, p. 127, May 2025, doi: 10.3390/computation13050127.
  - [20] P. V. Dantas, W. Sabino da Silva, L. C. Cordeiro, and C. B. Carvalho, “A comprehensive review of model compression techniques in machine learning,” *Appl. Intell.*, vol. 54, no. 22, pp. 11804–11844, Nov. 2024, doi: 10.1007/s10489-024-05747-w.
  - [21] S. F. D. Wardhana and A. Nugroho, “Perbandingan Arsitektur MobileNetV2 dan MobileNetV3 Dalam Klasifikasi Jenis Jeruk,” *J. Ilmu Komput. dan Bisnis*, vol. 16, no. 1, pp. 25–34, May 2025, doi: 10.47927/jikb.v16i1.916.
  - [22] D. B. Arianto and S. Nurrahmasita, “A Comparative Study For Imbalanced Data Techniques Of Classification Algorithms,” *Citiz. J. Ilm. Multidisiplin Indones.*, vol. 5, no. 4, pp. 1064–1073, Aug. 2025, doi: 10.53866/jimi.v5i4.949.
  - [23] N. Mukaromah and S. Mulyono, “Implementasi Stable Diffusion Dan Fine-Tuning Low Rank Adaptation Untuk Pembuatan Logo,” *J. Rekayasa Sist. Inf. dan Teknol.*, vol. 2, no. 3, pp. 973–984, Feb. 2025, doi: 10.70248/jrsit.v2i3.1885.
  - [24] R. E. Tilasefana, R. A., & Putra, “Penerapan Metode Deep Learning Menggunakan Algoritma CNN Dengan Arsitektur VGG NET Untuk Pengenalan Cuaca,” *J. Ilmu Komput.*, vol. 5, no. 3, p. 10, 2023, doi: 10.26740/jinacs.v5n01.p48-57.
  - [25] F. Amaludin, M. I. Zulfa, and H. Siswanto, “Pengaruh Hyperparameter Tuning Pada Kinerja Mobilenetv2 Dengan Transfer Learning Untuk Deteksi Penyakit Kulit,” *J. SINTA Sist. Inf. dan Teknol. Komputasi*, vol. 2, no. 2, May 2025, doi: 10.61124/sinta.v2i2.43.
  - [26] A. Prabowo and F. Indra Sanjaya, “Penerapan Metode Transfer Learning Pada Indobert Untuk Analisis Sentimen Teks Bahasa Jawa Ngoko Lugu,” *Simkom*, vol. 9, no. 2, pp. 205–217, Jul. 2024, doi: 10.51717/simkom.v9i2.478.
  - [27] I. Markoulidakis and G. Markoulidakis, “Probabilistic Confusion Matrix: A Novel Method for Machine Learning Algorithm Generalized Performance Analysis,” *Technologies*, vol. 12, no. 7, p. 113, Jul. 2024, doi: 10.3390/technologies12070113.
  - [28] S. Kantu, H. S. Kaja, V. Kukkala, S. A. Aly, and K. Sayed, “Integrating MobileNetV3 and SqueezeNet for Multi-class Brain Tumor Classification,” *J. Imaging Informatics Med.*, Jul. 2025, doi: 10.1007/s10278-025-01589-1.
  - [29] P. Choudhary, A. Jaiswal, D. Dash, A. Verma, S. Sharma, and N. Sharma, “Radiologist-Inspired Meniscus Injury Detection Using MobileNetV3-SVM with Grad-CAM Visualization,” *J. Med. Biol. Eng.*, Nov. 2025, doi: 10.1007/s40846-025-00991-y.
  - [30] H. I. Peyal *et al.*, “Plant Disease Classifier: Detection of Dual-Crop Diseases Using Lightweight 2D CNN Architecture,” *IEEE Access*, vol. 11, pp. 110627–110643, 2023, doi: 10.1109/ACCESS.2023.3320686.
  - [31] I. Karakostas, V. Mygdalis, N. Nikolaidis, and I. Pitas, “Enhancing visual object tracking robustness through a lightweight



- denoising module,” *Vis. Comput.*, vol. 41, no. 11, pp. 8627–8644, Sep. 2025, doi: 10.1007/s00371-025-03888-8.
- [32] O. A. Alrusaini, “Deep learning for steganalysis: evaluating model robustness against image transformations,” *Front. Artif. Intell.*, vol. 8, Mar. 2025, doi: 10.3389/frai.2025.1532895.
- [33] J. M. Gorriz, R. M. Clemente, F. Segovia, J. Ramirez, A. Ortiz, and J. Suckling, “Is K-fold cross validation the best model selection method for Machine Learning?,” Nov. 2024, [Online]. Available: <http://arxiv.org/abs/2401.16407>
- [34] W. Wijiyanto, A. I. Pradana, S. Sopingi, and V. Atina, “Teknik K-Fold Cross Validation untuk Mengevaluasi Kinerja Mahasiswa,” *J. Algoritma.*, vol. 21, no. 1, May 2024, doi: 10.33364/algoritma/v.21-1.1618.