



Implementasi Hybrid Feature Fusion menggunakan ResNet50 dan RGB-HSV untuk Klasifikasi Indikasi Tingkat Kepedasan Cabai Berdasarkan Karakteristik Visual

Febriyan Biopsa Minanda

Teknik Industri, Magister Informatika, Universitas Atma Jaya Yogyakarta, DI Yogyakarta, Indonesia

Email: biopza27@gmail.com

Abstrak—Cabai merupakan komoditas hortikultura yang memiliki variasi visual dan tingkat kepedasan berbeda, sehingga diperlukan metode klasifikasi yang objektif dan konsisten. Permasalahan dalam klasifikasi cabai adalah kemiripan karakteristik visual antar kategori serta penggunaan fitur warna atau fitur *deep learning* secara terpisah pada penelitian sebelumnya, sehingga informasi yang diperoleh belum komprehensif. Penelitian ini bertujuan menerapkan *hybrid feature fusion* menggunakan *ResNet50* dan fitur warna RGB-HSV untuk mengklasifikasikan indikasi tingkat kepedasan cabai ke dalam kategori *Hot*, *Medium*, dan *Mild* berdasarkan karakteristik visual. Kebaruan penelitian terletak pada integrasi fitur mendalam *ResNet50* dengan fitur RGB-HSV dalam satu representasi fitur, karena *ResNet50* mampu menangkap pola visual kompleks, sedangkan RGB-HSV memberikan informasi warna secara eksplisit. Penelitian menggunakan pendekatan kuantitatif dengan metodologi eksperimen berbasis pengolahan citra dan *deep learning*. Dataset terdiri dari 1.592 citra cabai, meliputi 416 citra *Hot*, 514 citra *Medium*, dan 662 citra *Mild*. Data dibagi dengan rasio 70:15:15, yaitu 1.114 citra *training*, 239 citra *validation*, dan 239 citra *testing*. Pemrosesan dilakukan melalui penghapusan *background* menggunakan *rembg*, perubahan ukuran citra menjadi 224×224 piksel, serta ekstraksi fitur *mean* dan *standard deviation* pada kanal RGB dan HSV. Model menghasilkan *accuracy* 96,23%, *precision* 96,10%, *recall* 96,08%, dan *F1-score* 96,08%, lebih tinggi dibandingkan citra asli. Temuan ini menunjukkan bahwa integrasi fitur mendalam dan fitur warna meningkatkan kinerja klasifikasi cabai.

Kata Kunci: Cabai; *Hybrid Feature Fusion*; *ResNet50*; RGB-HSV; Klasifikasi

Abstract—Chili is a horticultural commodity with diverse visual characteristics and different levels of pungency, requiring an objective and consistent classification method. A challenge in chili classification is the similarity of visual characteristics across categories and the separate use of color features or *deep learning* features in previous studies, resulting in less comprehensive information representation. This study aims to implement *hybrid feature fusion* using *ResNet50* and RGB-HSV color features to classify indications of chili pungency into *Hot*, *Medium*, and *Mild* categories based on visual characteristics. The novelty of this study lies in integrating deep features from *ResNet50* with RGB-HSV features into a single feature representation, as *ResNet50* can capture complex visual patterns, while RGB-HSV explicitly provides color information. This study employed a quantitative approach with an experimental methodology based on image processing and *deep learning*. The dataset consisted of 1,592 chili images, including 416 *Hot*, 514 *Medium*, and 662 *Mild* images. The data were divided at a 70:15:15 ratio into 1,114 training, 239 validation, and 239 testing images. Preprocessing included background removal using *rembg*, resizing images to 224×224 pixels, and extracting *mean* and *standard deviation* features from RGB and HSV channels. The model achieved 96.23% accuracy, 96.10% precision, 96.08% recall, and a 96.08% F1-score, outperforming the original image model. These findings indicate that integrating deep and color features improves chili classification performance.

Keywords: Chili; *Hybrid Feature Fusion*; *ResNet50*; RGB-HSV; Classification

1. PENDAHULUAN

Cabai merupakan salah satu komoditas hortikultura terpenting di Indonesia karena penggunaannya yang luas sebagai bahan makanan, bumbu masakan, dan bahan baku berbagai produk olahan, sehingga memiliki nilai ekonomi yang tinggi (Kaswar dkk., 2023). Kualitas cabai ditentukan oleh beberapa faktor, termasuk penampilan fisik, warna, kematangan, dan konsistensi setelah panen, karena karakteristik ini memengaruhi kualitas produk, rasa, nilai gizi, dan daya jual (Kaswar dkk., 2023). Selain itu, keberadaan berbagai varietas cabai dengan karakteristik visual yang berbeda membuat proses klasifikasi menjadi lebih menantang dan membutuhkan akurasi tinggi untuk memenuhi permintaan pasar (Rohman dkk., 2024). Akibatnya, pengolahan citra dan teknologi kecerdasan buatan menjadi solusi yang menjanjikan untuk mengembangkan sistem klasifikasi cabai yang lebih objektif dan efisien (Kamilah & Fatah, 2024).

Menurut Badan Pusat Statistik (BPS), Indonesia memproduksi 17.431.254,35 kuintal cabai rawit pada tahun 2025, yang menunjukkan skala produksi yang besar sehingga memerlukan proses penyortiran dan klasifikasi yang efisien dan konsisten (BPS, 2026). Pada periode yang sama, produksi cabai rawit mencapai 3.871.164,47 kuintal, yang semakin menekankan pentingnya strategis budidaya cabai rawit dalam industri hortikultura negara (BPS, 2026). Selain itu, data dari Pusat Data dan Sistem Informasi Pertanian (2025) menunjukkan bahwa konsumsi cabai rawit tahunan rumah tangga meningkat dari 1,298 kg per kapita pada tahun 2010 menjadi 2,125 kg per kapita pada tahun 2024 dan diproyeksikan mencapai 2,279 kg per kapita pada tahun 2025. Pertumbuhan yang stabil baik dalam produksi maupun konsumsi menggarisbawahi pentingnya pengembangan metode klasifikasi yang andal untuk meningkatkan pengendalian mutu pasca panen dan efisiensi operasional.

Salah satu tantangan utama dalam klasifikasi cabai adalah ketergantungan pada inspeksi visual manual. Evaluasi kematangan cabai melalui pengamatan manusia pada dasarnya bersifat subjektif karena dapat dipengaruhi oleh persepsi individu, kelelahan, dan keterbatasan perhatian (Ulum dkk., 2024). Inspeksi manual juga berpotensi menimbulkan kesalahan dalam proses penyortiran, terutama ketika cabai diproses dalam jumlah besar (Hadi dkk., 2025). Selain itu,



variasi warna yang disebabkan oleh tahap pematangan, kondisi pencahayaan, dan sudut pengambilan citra dapat mengurangi konsistensi hasil klasifikasi. Keterbatasan tersebut menunjukkan perlunya sistem otomatis berbasis citra yang mampu mengekstraksi karakteristik visual secara objektif dan menghasilkan klasifikasi cabai yang lebih konsisten.

Studi sebelumnya telah menunjukkan efektivitas teknik pengolahan citra dan pembelajaran mesin untuk klasifikasi cabai. Pendekatan yang menggabungkan *Convolutional Neural Network* (CNN) dengan algoritma *K-Nearest Neighbor* (KNN) mampu mengklasifikasikan tingkat kematangan cabai rawit dengan akurasi maksimum sebesar 95,33%. Pendekatan tersebut memiliki kemampuan dalam mengekstraksi pola visual secara otomatis, tetapi klasifikasi yang dilakukan masih berfokus pada tingkat kematangan dan belum mengintegrasikan fitur warna secara eksplisit ke dalam proses klasifikasi (Ulum dkk., 2024). Pendekatan lain menggunakan *Support Vector Machine* (SVM) multikelas dengan statistik warna RGB berupa nilai rata-rata, varians, dan rentang serta menghasilkan akurasi sebesar 95,33%. Metode tersebut memiliki kemampuan untuk memanfaatkan karakteristik warna secara langsung, tetapi masih bergantung pada fitur warna yang dirancang secara manual sehingga representasi karakteristik visual yang lebih kompleks belum dapat dipelajari secara otomatis (Irma dkk., 2024).

Penggunaan arsitektur *LeNet-5* dan *MobileNet-V2* juga menunjukkan kemampuan yang baik dalam klasifikasi kematangan cabai berbasis *computer vision*. Pendekatan *deep learning* tersebut memiliki keunggulan dalam mempelajari fitur citra secara otomatis, tetapi masih diarahkan pada klasifikasi kematangan dan belum menggabungkan fitur mendalam dengan informasi warna RGB-HSV secara khusus (Hadi dkk., 2025). Model berbasis *Teachable Machine* juga mampu mengklasifikasikan kematangan cabai dengan akurasi sebesar 92%, namun pendekatan tersebut lebih menekankan proses klasifikasi berbasis model siap pakai sehingga eksplorasi terhadap mekanisme ekstraksi dan penggabungan fitur masih terbatas (Kamilah & Fatah, 2024). Selain itu, pendekatan CNN telah digunakan untuk mengklasifikasikan jenis cabai berdasarkan karakteristik warna dan bentuk. Pendekatan tersebut menunjukkan bahwa karakteristik visual dapat digunakan untuk membedakan objek cabai, tetapi fokus klasifikasi masih pada jenis cabai dan belum diarahkan pada klasifikasi indikasi tingkat kepedasan (Rohman dkk., 2024).

Berdasarkan perbandingan penelitian terdahulu tersebut, dapat diketahui bahwa metode berbasis *deep learning* memiliki keunggulan dalam mengekstraksi pola visual secara otomatis, sedangkan pendekatan berbasis fitur warna mampu memberikan informasi warna yang lebih eksplisit. Namun, belum ditemukan penelitian yang secara khusus mengintegrasikan fitur mendalam dari *ResNet50* dengan fitur warna RGB-HSV melalui pendekatan *hybrid feature fusion* untuk klasifikasi indikasi tingkat kepedasan cabai berdasarkan karakteristik visual. Penelitian sebelumnya lebih banyak berfokus pada klasifikasi tingkat kematangan atau jenis cabai dengan menggunakan fitur *deep learning* maupun fitur warna secara terpisah. Oleh karena itu, celah penelitian ini terletak pada integrasi kedua jenis fitur tersebut untuk memperoleh representasi karakteristik visual cabai yang lebih komprehensif.

Untuk mengatasi keterbatasan ini, penelitian ini mengusulkan penggunaan pendekatan *hybrid feature fusion*. Metode ini mengintegrasikan fitur mendalam yang diekstrak oleh jaringan saraf konvolusional dengan fitur warna buatan tangan untuk mendapatkan representasi fitur yang lebih kaya dan lebih diskriminatif. Secara khusus, fitur warna RGB dan HSV digunakan untuk mengkarakterisasi sifat warna visual cabai, di mana RGB mewakili intensitas saluran merah, hijau, dan biru, sedangkan HSV menggambarkan warna dalam hal rona, saturasi, dan nilai (Ningrum dkk., 2024).

Selain itu, ekstraksi fitur merupakan langkah pra-pemrosesan yang penting dalam klasifikasi kualitas cabai berbasis citra karena memungkinkan karakteristik visual untuk direpresentasikan secara lebih efektif sebelum klasifikasi (Mahdiyah, 2023). Dengan menggabungkan kemampuan ekstraksi fitur *ResNet50* dengan informasi warna RGB dan HSV, pendekatan fusi fitur hibrida yang diusulkan diharapkan dapat mencapai kinerja klasifikasi yang lebih unggul dibandingkan dengan metode yang hanya mengandalkan satu jenis fitur.

Studi ini menerapkan pendekatan *hybrid feature fusion* dengan menggabungkan fitur mendalam dari *ResNet50* dan fitur warna RGB-HSV untuk mengklasifikasikan indikasi tingkat kepedasan cabai berdasarkan karakteristik visual. Permasalahan yang dikaji mencakup kemampuan integrasi kedua jenis fitur tersebut dalam membedakan cabai ke dalam kategori *Hot*, *Medium*, dan *Mild*, serta kinerja model yang dihasilkan berdasarkan nilai *accuracy*, *precision*, *recall*, dan *F1-score*. Fitur warna RGB dan HSV diekstraksi dari citra cabai dan digabungkan dengan fitur mendalam yang dihasilkan oleh *ResNet50* untuk membentuk representasi fitur yang lebih komprehensif. Dengan demikian, penelitian ini bertujuan mengimplementasikan dan mengevaluasi pendekatan *hybrid feature fusion ResNet50* dan RGB-HSV dalam klasifikasi indikasi tingkat kepedasan cabai berdasarkan karakteristik visual.

2. METODOLOGI PENELITIAN

2.1 Kerangka Dasar Penelitian

Penelitian ini menggunakan pendekatan kuantitatif karena data yang dianalisis berupa citra digital cabai yang diolah menjadi nilai numerik, seperti fitur warna RGB-HSV serta nilai performa model. Metodologi yang digunakan adalah eksperimen berbasis pengolahan citra dan *deep learning*, dengan tahapan meliputi pengumpulan data, pemrosesan citra, ekstraksi fitur, pembentukan model *ResNet50*, *training*, evaluasi, dan prediksi. Pendekatan ini digunakan untuk mengukur kemampuan model secara objektif dalam mengklasifikasikan tingkat kepedasan cabai ke dalam kategori *Hot*, *Medium*, dan *Mild* berdasarkan metrik *accuracy*, *precision*, *recall*, dan *f1-score*.

2.2 Tahapan Penelitian

Tahapan penelitian ini disusun untuk menggambarkan tahapan klasifikasi tingkat kepedasan cabai menggunakan pendekatan pengolahan citra dan pembelajaran mesin. Tahapan penelitian dilakukan secara sistematis mulai dari pengumpulan data hingga proses prediksi kelas kepedasan cabai. Secara umum, alur penelitian yang digunakan dalam penelitian ini ditampilkan pada Gambar 1.



Gambar 1. Tahapan Penelitian


Gambar 1 menunjukkan bahwa penelitian ini terdiri dari enam tahapan utama, yaitu pengumpulan data, pemrosesan data, pembentukan model, *training* model, evaluasi model, dan prediksi. Setiap tahapan saling berhubungan karena hasil dari tahap sebelumnya menjadi masukan bagi tahap berikutnya.

1. Pengumpulan data: Data dikumpulkan dalam bentuk citra cabai yang diperoleh melalui proses pemotretan secara langsung.
2. Pemrosesan data: Citra cabai yang telah dikumpulkan diproses untuk memperoleh data yang lebih bersih dan siap digunakan dalam pelatihan model.
3. Pembentukan model: Model klasifikasi dibangun menggunakan pendekatan *hybrid feature fusion* yang menggabungkan fitur citra dari *ResNet50* dengan fitur warna RGB dan HSV.
4. *Training* model: Model dilatih menggunakan dataset cabai yang telah diproses agar mampu mengenali pola visual pada masing-masing kategori kepedasan.
5. Evaluasi model: Model yang telah dilatih dievaluasi untuk mengetahui performa klasifikasi berdasarkan metrik *accuracy*, *precision*, *recall*, dan *f1-score*.
6. Prediksi: Model yang telah dievaluasi digunakan untuk memprediksi tingkat kepedasan cabai berdasarkan citra masukan.

Tahapan-tahapan tersebut digunakan untuk memastikan bahwa proses klasifikasi dilakukan secara terstruktur dan terukur. Penjelasan lebih rinci mengenai setiap tahapan penelitian akan dijelaskan pada bagian selanjutnya.

2.3 Pengumpulan Data

Pengumpulan data dilakukan secara manual dengan memotret cabai sebagai objek utama penelitian. Proses pengambilan citra dilakukan dengan mengikuti cara pengambilan data yang ditampilkan pada Gambar 2 agar posisi objek dan jarak pengambilan citra lebih konsisten. Pengambilan citra dilakukan menggunakan *smartphone* dengan spesifikasi kamera belakang berupa konfigurasi *Quad Camera*, yaitu lensa utama 50MP dengan OIS/anti-guncang, 5MP *ultrawide*, 2MP *macro*, dan 2MP *depth*.



Gambar 2. Cara Pengambilan Data

Cabai yang digunakan dalam penelitian ini dikelompokkan ke dalam tiga kategori tingkat kepedasan, yaitu *Hot*, *Medium*, dan *Mild*. Penentuan kategori tersebut mengacu pada karakteristik visual warna cabai yang disesuaikan dengan kaidah tingkat kepedasan pada *Scoville Level*. Gambaran kategori tingkat kepedasan cabai berdasarkan *Scoville Level* ditampilkan pada Gambar 3.



Gambar 3. *Scoville Level*

Cabai yang digunakan dalam penelitian ini dikelompokkan ke dalam tiga kategori tingkat kepedasan, yaitu *Hot*, *Medium*, dan *Mild*. Penentuan kategori tersebut mengacu pada karakteristik visual warna cabai yang disesuaikan dengan kaidah tingkat kepedasan pada *Scoville Level* (Cini, 2025). Gambaran kategori tingkat kepedasan cabai berdasarkan *Scoville Level* ditampilkan pada Gambar 3. Adapun pembagian tingkat kepedasan berdasarkan *Scoville Heat Unit* (SHU) dijelaskan sebagai berikut:

1. *Mild*: kategori dengan tingkat kepedasan rendah, yaitu berada pada rentang 0–2.500 SHU.
2. *Medium*: kategori dengan tingkat kepedasan sedang, yaitu berada pada rentang 2.500–15.000 SHU.
3. *Hot*: kategori dengan tingkat kepedasan tinggi, yaitu berada pada rentang 15.000–100.000 SHU.

Berdasarkan pengelompokan tingkat kepedasan tersebut, citra cabai selanjutnya disusun ke dalam tiga kategori, yaitu *Hot*, *Medium*, dan *Mild*. Setiap kategori memiliki sampel citra dengan karakteristik visual yang berbeda dan digunakan sebagai dasar dalam penyusunan dataset penelitian. Contoh citra dari masing-masing kategori tersebut ditampilkan pada Tabel 1.

Tabel 1. Sampel *Dataset*

<i>Hot</i>	<i>Medium</i>	<i>Mild</i>
		
		
		

Tabel 1 menampilkan contoh citra cabai yang digunakan sebagai *dataset* dalam penelitian ini. Secara keseluruhan, jumlah data yang dikumpulkan sebanyak 1.592 citra yang terbagi ke dalam tiga kategori. Kategori *Hot* terdiri dari 416 citra, kategori *Medium* terdiri dari 514 citra, dan kategori *Mild* terdiri dari 662 citra.

2.4 Pemrosesan Data

Pemrosesan data dilakukan untuk menyiapkan citra cabai sebelum proses pelatihan model. Tahap awal berupa penghapusan latar belakang menggunakan *rembg* yang dikembangkan oleh Daniel Gatis (Gatis, 2026). Proses ini bertujuan agar model lebih berfokus pada objek cabai dan mengurangi pengaruh latar belakang yang tidak relevan. Proses segmentasi atau pemisahan objek utama dari latar belakang dapat membantu analisis citra menjadi lebih terfokus pada karakteristik objek yang akan diklasifikasikan (Mujidah & Agustin, 2024; Permata & Ramadhanu, 2025). Selanjutnya, seluruh citra diubah ukurannya menjadi 224×224 piksel supaya sesuai dengan format masukan arsitektur *ResNet50*. Ukuran ini dipilih karena merupakan standar *input* model sehingga proses pengolahan citra dapat dilakukan secara optimal (Wasilah dkk., 2025).

Tahap berikutnya adalah ekstraksi fitur warna menggunakan ruang warna RGB dan HSV. RGB dimanfaatkan untuk merepresentasikan komponen warna dasar citra digital (Irma dkk., 2024), sedangkan HSV digunakan untuk menggambarkan karakteristik warna berdasarkan *Hue*, *Saturation*, dan *Value* yang lebih efektif dalam menganalisis perubahan warna pada cabai (Napitu dkk., 2023). Kombinasi kedua ruang warna tersebut dinilai mampu meningkatkan



representasi karakteristik warna untuk proses klasifikasi (Irma dkk., 2024).

Selain tahapan tersebut, dilakukan pemrosesan nilai *input* sebelum data digunakan dalam model. Citra diproses menggunakan fungsi *preprocess input* sesuai dengan kebutuhan masukan *ResNet50*, sedangkan fitur RGB-HSV dinormalisasi menggunakan *StandardScaler* yang di-fit pada data *training* dan kemudian diterapkan pada data *validation* serta *testing* untuk mencegah terjadinya *data leakage* (Wasilah dkk., 2025). Pada data *training* juga diterapkan *data augmentation* berupa *horizontal flipping*, rotasi 0,08, *zoom* 0,10, translasi horizontal dan vertikal 0,05, serta perubahan kontras 0,10 untuk meningkatkan variasi citra selama proses pelatihan dan membantu mengurangi risiko *overfitting* (Sujaka dkk., 2025). Augmentasi dilakukan sebelum tahap *preprocess input* dan sebelum citra diteruskan ke *ResNet50*.

Fitur yang diekstraksi dari masing-masing kanal warna adalah nilai *mean* dan *standard deviation*. Nilai *mean* digunakan untuk mengetahui rata-rata intensitas warna pada setiap kanal, sebagaimana ditunjukkan pada Persamaan (1).

$$\text{mean } C = \frac{\sum x_i}{n} \quad (1)$$

Pada Persamaan (1), *mean C* adalah rata-rata piksel pada kanal *Red*, *Green*, *Blue*, *Hue*, *Saturation*, atau *Value*, x_i adalah nilai piksel ke- i , dan n adalah jumlah piksel. Nilai *standard deviation* digunakan untuk melihat variasi intensitas warna, sebagaimana ditunjukkan pada Persamaan (2).

$$\text{std } C = \sqrt{\frac{\sum (x_i - \text{mean } C)^2}{n}} \quad (2)$$

Hasil pemrosesan data ditampilkan pada Tabel 2 dalam bentuk citra bersih serta nilai fitur RGB dan HSV dari masing-masing kategori cabai. Tabel 2 memuat nilai *mean* dan *standard deviation* pada kanal *Red/Hue*, *Green/Saturation*, dan *Blue/Value* untuk kategori *Hot*, *Medium*, dan *Mild*. Hasil ekstraksi tersebut digunakan sebagai fitur warna yang akan digabungkan dengan fitur citra dari *ResNet50* pada tahap pembentukan model.

Tabel 2. Hasil Pemrosesan Data

Ekstraksi	Hot			Medium			Mild		
	Citra Bersih	RGB	HSV	Citra Bersih	RGB	HSV	Citra Bersih	RGB	HSV
<i>mean</i> (R/H)		150.99	19.17		146.46	19.57		142.37	25.89
<i>std</i> (R/H)		25.12	46.66		29.47	8.53		27.54	4.47
<i>mean</i> (G/S)		41.85	208.73		104.60	193.19		125.03	201.40
<i>std</i> (G/S)		25.05	38.69		35.56	37.47		21.89	35.08
<i>mean</i> (B/V)		25.93	152.42		35.68	147.32		30.24	143.91
<i>std</i> (B/V)		19.65	22.81		24.29	28.53		21.19	24.96
<i>mean</i> (R/H)		151.41	10.92		129.48	20.14		154.97	23.09
<i>std</i> (R/H)		28.64	23.41		35.44	9.81		25.98	6.62
<i>mean</i> (G/S)		51.65	207.39		89.92	199.54		126.39	175.18
<i>std</i> (G/S)		20.66	207.39		27.69	37.11		28.41	50.77
<i>mean</i> (B/V)		25.78	152.44		27.22	131.67		47.78	155.63
<i>std</i> (B/V)		21.69	26.32		18.80	32.24		31.10	25.48
<i>mean</i> (R/H)		146.41	32.63		160.70	23.70		162.48	25.10
<i>std</i> (R/H)		35.30	59.68		35.66	4.58		30.79	7.91
<i>mean</i> (G/S)		56.71	175.88		132.82	194.44		142.57	153.20
<i>std</i> (G/S)		24.42	41.76		32.44	37.18		24.57	37.48
<i>mean</i> (B/V)		45.05	147.70		38.45	161.64		64.09	163.13
<i>std</i> (B/V)		24.68	32.93		27.60	34.64		24.05	29.59


Berdasarkan Tabel 2, setiap kategori cabai memiliki perbedaan nilai fitur warna pada ruang warna RGB maupun HSV. Perbedaan nilai *mean* menunjukkan adanya variasi dominasi warna pada setiap kategori cabai. Sementara itu, nilai *standard deviation* menunjukkan tingkat sebaran atau variasi warna dalam citra, sehingga fitur RGB dan HSV dapat digunakan sebagai informasi tambahan untuk membedakan tingkat kepedasan cabai secara lebih representatif.

2.5 Pembentukan Model

Pembentukan model dilakukan setelah seluruh citra melalui tahap pemrosesan data dan ekstraksi fitur warna. Pada tahap ini, model dibangun dengan menggabungkan kemampuan ekstraksi fitur mendalam dari *ResNet50* dan fitur warna hasil ekstraksi RGB-HSV. Pendekatan ini digunakan agar model tidak hanya mengenali pola visual secara umum, tetapi juga mempertimbangkan karakteristik warna yang menjadi indikator penting dalam klasifikasi tingkat kepedasan cabai.

2.5.1 ResNet50

ResNet50 digunakan sebagai arsitektur utama untuk mengekstraksi fitur mendalam dari citra cabai. Arsitektur *ResNet50* dalam penelitian ini ditampilkan pada Gambar 4 sebagai contoh alur *residual connection* yang menjadi ciri utama model tersebut.




Gambar 4. Arsitektur ResNet50

Gambar 4 menunjukkan konsep *residual connection*, yaitu adanya jalur pintas yang memungkinkan informasi dari lapisan awal diteruskan ke lapisan berikutnya. Mekanisme ini membantu model mempertahankan informasi penting dan mengurangi risiko penurunan performa pada jaringan yang dalam, sehingga *ResNet50* banyak digunakan dalam tugas klasifikasi citra (Noviana & Sudiro, 2024). *ResNet50* juga dinilai efektif dalam mengenali pola visual seperti bentuk, warna, dan tekstur pada objek citra, termasuk pada klasifikasi produk segar berbasis gambar (Wasilah dkk., 2025).

2.5.2 Feature Fusion

Feature fusion dilakukan untuk menggabungkan fitur mendalam dari *ResNet50* dengan fitur warna RGB dan HSV yang telah diekstraksi sebelumnya. Alur pembentukan *feature fusion* dalam penelitian ini ditampilkan pada Gambar 5.



Gambar 5. Alur *Feature Fusion*

Gambar 5 menunjukkan bahwa citra cabai terlebih dahulu melalui proses penghapusan *background*, kemudian diproses melalui dua jalur ekstraksi fitur. Pada jalur pertama, citra diproses menggunakan *ResNet50*, kemudian hasil ekstraksi fitur diteruskan ke *Global Average Pooling*, *Batch Normalization*, *Dense layer 256 neuron* dengan aktivasi ReLU, *dropout 0,35*, dan *Dense layer 128 neuron* dengan aktivasi ReLU sehingga menghasilkan vektor fitur mendalam berukuran 128 dimensi. Pada jalur kedua, fitur warna terdiri atas 12 fitur berupa nilai *mean* dan *standard deviation* dari kanal R, G, B, H, S, dan V, kemudian diproses melalui *Batch Normalization*, *Dense layer 64 neuron* dengan aktivasi ReLU, *dropout 0,20*, dan *Dense layer 32 neuron* dengan aktivasi ReLU sehingga menghasilkan vektor fitur warna berukuran 32 dimensi. [REVISI] Kedua vektor fitur tersebut digabungkan menggunakan teknik *concatenation*, sehingga vektor fitur *ResNet50* berdimensi 128 dan fitur warna berdimensi 32 membentuk vektor gabungan berdimensi 160. Vektor hasil *fusion* selanjutnya diteruskan ke *Dense layer 128 neuron* dengan aktivasi ReLU, *Batch Normalization*, dan *dropout 0,40*, kemudian ke lapisan keluaran tiga *neuron* dengan aktivasi *softmax* untuk menghasilkan klasifikasi akhir berupa kategori *Hot*, *Medium*, atau *Mild*.

Pendekatan *feature fusion* digunakan karena penggabungan beberapa jenis fitur dapat menghasilkan representasi citra yang lebih lengkap dalam membedakan karakteristik objek cabai. Dalam penelitian ini, fitur mendalam dari *ResNet50* digunakan untuk merepresentasikan pola visual kompleks, sedangkan fitur RGB-HSV memberikan informasi warna secara eksplisit. Penggabungan keduanya melalui *concatenation* memungkinkan kedua jenis informasi dipertahankan dalam satu representasi sebelum proses klasifikasi. Pendekatan *hybrid feature fusion* dan *deep learning* juga telah digunakan pada deteksi penyakit antraknosa tanaman cabai dan menunjukkan bahwa penggabungan fitur dapat meningkatkan kemampuan model dalam mengenali karakteristik visual tanaman cabai (Tiwari dkk., 2025). Selain itu, integrasi fitur warna dan bentuk pada klasifikasi jenis cabai berbasis CNN juga dilaporkan mampu meningkatkan akurasi dan kemampuan generalisasi model (Rohman dkk., 2024).

2.6 Training Model

Training model dilakukan dengan membagi *dataset* menjadi data latih, validasi, dan uji menggunakan rasio 70:15:15. Dari total 1.592 citra, sebanyak 1.114 citra digunakan untuk *training*, 239 citra untuk *validation*, dan 239 citra untuk

testing. Pembagian *dataset* ini bertujuan agar model dapat belajar dari data latih, dipantau melalui data validasi, dan diuji pada data yang belum pernah dikenali sebelumnya, sebagaimana diterapkan pada penelitian klasifikasi citra cabai berbasis *deep learning* (Sujaka dkk., 2025).


Pelatihan model dilakukan menggunakan *batch size* 16, *epoch* 15, *optimizer Adam*, dan *learning rate* 0,001. *Adam* dipilih karena umum digunakan dalam pelatihan model CNN untuk klasifikasi citra dan mampu membantu proses optimasi model secara efisien (Rohman dkk., 2024). Selama proses pelatihan, kinerja model dipantau melalui *learning curve* berdasarkan perubahan *accuracy* dan *loss* pada data *training* dan *validation* untuk melihat perkembangan proses pembelajaran model (Sujaka dkk., 2025; Wasilah dkk., 2025). Untuk mengurangi risiko *overfitting*, digunakan *EarlyStopping* dengan pemantauan terhadap *validation loss* dan nilai *patience* sebesar 5, serta *ReduceLROnPlateau* dengan faktor penurunan *learning rate* sebesar 0.2 ketika *validation loss* tidak mengalami perbaikan selama dua *epoch*. Setelah pelatihan awal, dilakukan *fine-tuning* pada 30 lapisan terakhir *ResNet50* dengan *learning rate* 0,00001 dan maksimum 10 *epoch* tambahan sebagai tahap penyesuaian model terhadap karakteristik data penelitian, sejalan dengan penggunaan pendekatan *transfer learning* pada klasifikasi citra cabai (Sujaka dkk., 2025). Pelatihan dilakukan dalam dua skenario, yaitu menggunakan citra asli dan citra bersih yang dikombinasikan dengan fitur RGB-HSV, sehingga performa kedua pendekatan dapat dibandingkan.

3. HASIL DAN PEMBAHASAN

Bagian ini memaparkan hasil pengujian model dalam mengklasifikasikan tingkat kepedasan cabai ke dalam tiga kategori, yaitu *Hot*, *Medium*, dan *Mild*. Evaluasi dilakukan dengan membandingkan performa model yang menggunakan citra asli dengan model yang memanfaatkan citra hasil penghapusan background yang dipadukan dengan fitur warna RGB-HSV.

3.1 Evaluasi Model

Evaluasi dilakukan untuk mengukur kemampuan model dalam mengenali karakteristik citra pada setiap kelas cabai. Hasil pengujian disajikan dalam Gambar 6 berupa perbandingan grafik *accuracy* dan *loss*, Tabel 3 yang menampilkan *classification report*, serta Gambar 7 yang memperlihatkan perbandingan *confusion matrix*.



Gambar 6. Perbandingan Grafik *Accuracy* dan *Loss*


Berdasarkan Gambar 6, model yang menggunakan citra asli menunjukkan peningkatan nilai *accuracy* secara bertahap selama proses *training* maupun *validation*. Sementara itu, model yang menggunakan citra bersih dengan penambahan fitur RGB-HSV memiliki nilai *accuracy* yang lebih tinggi serta lebih stabil sejak awal proses pelatihan. Di sisi lain, nilai *loss* pada model tersebut mengalami penurunan yang lebih rendah dibandingkan model citra asli, sehingga mengindikasikan bahwa proses pembelajaran berlangsung dengan lebih optimal. Perbedaan performa kedua model tersebut selanjutnya ditunjukkan secara kuantitatif melalui hasil *classification report* yang disajikan pada Tabel 3.

Tabel 3. Hasil *Classification Report*

Metrik	Input Citra Asli	Input Citra Bersih + RGB-HSV
Accuracy	0.8703	0.9623

Metrik	Input Citra Asli	Input Citra Bersih + RGB-HSV
Recall	0.8690	0.9608
Precision	0.8721	0.9610
F1-score	0.8696	0.9608

Hasil pada Tabel 3 memperlihatkan bahwa model yang menggunakan citra bersih dengan kombinasi fitur RGB-HSV memperoleh nilai *accuracy* sebesar 0,9623, lebih tinggi dibandingkan model yang menggunakan citra asli dengan nilai 0,8703. Peningkatan juga terlihat pada nilai *precision*, yaitu dari 0,8721 menjadi 0,9610, yang menunjukkan bahwa model semakin akurat dalam melakukan prediksi terhadap setiap kelas cabai. Nilai *recall* turut mengalami peningkatan dari 0,8690 menjadi 0,9608, sehingga kemampuan model dalam mengenali seluruh data pada masing-masing kategori menjadi lebih baik. Selain itu, *f1-score* sebesar 0,9608 mengindikasikan bahwa penggunaan citra bersih yang dipadukan dengan fitur RGB-HSV mampu menghasilkan keseimbangan yang baik antara nilai *precision* dan *recall*.



Gambar 7. Perbandingan *Confusion Matrix*

Berdasarkan Gambar 7, model yang menggunakan citra asli masih menunjukkan beberapa kesalahan dalam proses klasifikasi. Kesalahan paling banyak terjadi pada kategori *Mild*, yang diprediksi sebagai *Medium* sebanyak 12 citra. Sebaliknya, model yang memanfaatkan citra bersih dengan fitur RGB-HSV menghasilkan jumlah prediksi yang benar lebih tinggi pada seluruh kategori, yaitu 60 citra untuk kelas *Hot*, 74 citra untuk kelas *Medium*, dan 96 citra untuk kelas *Mild*. Temuan tersebut menunjukkan bahwa penerapan penghapusan *background* serta penambahan fitur warna RGB-HSV mampu meningkatkan kemampuan model dalam membedakan tingkat kepedasan cabai secara lebih akurat.

3.2 Prediksi

Tahap prediksi dilakukan untuk mengetahui kemampuan model dalam mengklasifikasikan citra cabai baru setelah proses training dan evaluasi selesai dilakukan. Visualisasi implementasi prediksi model ditampilkan pada Gambar 8.




Gambar 8. Implementasi Prediksi



Implementasi prediksi dilakukan menggunakan 10 sampel gambar cabai di luar *dataset* utama. Sepuluh citra tersebut diambil dari internet, kemudian diproses menggunakan model *ResNet50* dengan citra bersih yang dikombinasikan dengan fitur RGB-HSV. Hasil prediksi dari 10 sampel citra tersebut ditampilkan pada Tabel 4.

Tabel 4. 10 Sampel Hasil Prediksi

Citra Asli	Label Asli	Prediksi	Confidence	Status
	Hot	Hot	56.78%	Sesuai
	Medium	Mild	75.89%	Tidak Sesuai
	Mild	Mild	94.69%	Sesuai
	Medium	Medium	99.64%	Sesuai
	Medium	Medium	98.65%	Sesuai
	Hot	Hot	99.97%	Sesuai
	Hot	Hot	95.66%	Sesuai
	Mild	Mild	57.69%	Sesuai
	Medium	Medium	59.50%	Sesuai
	Hot	Medium	97.14%	Tidak Sesuai

Berdasarkan Tabel 4, dari 10 sampel citra cabai yang diuji, model mampu menghasilkan prediksi yang sesuai pada sebagian besar data, terutama pada kategori *Hot*, *Medium*, dan *Mild* dengan nilai *confidence* yang cukup bervariasi mulai dari 56,78% hingga 99,97%. Nilai *confidence* yang tinggi pada beberapa sampel, seperti kategori *Medium* sebesar 99,64% dan kategori *Hot* sebesar 99,97%, menunjukkan bahwa model memiliki keyakinan kuat dalam mengenali pola visual cabai setelah citra dibersihkan dan dikombinasikan dengan fitur RGB-HSV. Namun, masih terdapat kesalahan prediksi pada sampel dengan label asli *Hot* yang diprediksi sebagai *Medium* dengan *confidence* 97,14%, sehingga dapat disimpulkan bahwa model masih memiliki keterbatasan dalam membedakan cabai dengan karakteristik warna yang mirip antar kategori.

3.3 Pembahasan

Hasil penelitian menunjukkan bahwa model dengan citra bersih yang dikombinasikan dengan fitur RGB-HSV menghasilkan performa lebih baik dibandingkan model dengan citra asli. Nilai *accuracy* meningkat dari 0,8703 menjadi 0,9623, sedangkan *f1-score* meningkat dari 0,8696 menjadi 0,9608. Peningkatan performa tersebut menunjukkan bahwa penghapusan *background* membantu mengurangi informasi visual yang tidak relevan sehingga model dapat lebih berfokus pada karakteristik objek cabai, sedangkan *ResNet50* berperan dalam mengekstraksi fitur mendalam berupa pola visual yang lebih kompleks, seperti bentuk, tekstur, dan struktur objek. Kemampuan *ResNet50* dalam mengekstraksi karakteristik visual secara otomatis memberikan representasi yang lebih kaya dibandingkan penggunaan fitur warna saja, sehingga mendukung proses klasifikasi citra secara lebih efektif (Wasilah dkk., 2025).

Selain fitur mendalam, RGB dan HSV memberikan kontribusi yang berbeda tetapi saling melengkapi dalam proses klasifikasi. Fitur RGB merepresentasikan intensitas warna merah, hijau, dan biru secara langsung sehingga mampu menangkap perbedaan dominasi warna antarobjek cabai. Penggunaan statistik warna RGB juga telah menunjukkan kemampuan yang baik dalam membedakan tingkat kematangan cabai merah keriting dengan akurasi sebesar 95,33% (Irma dkk., 2024). Sementara itu, HSV merepresentasikan warna melalui komponen *Hue*, *Saturation*, dan *Value* sehingga memberikan informasi tambahan mengenai karakteristik rona, tingkat kejenuhan, dan kecerahan warna yang tidak direpresentasikan secara terpisah dalam RGB. Penggunaan kombinasi RGB dan HSV telah dimanfaatkan untuk membedakan karakteristik objek berdasarkan informasi warna sehingga kedua ruang warna dapat saling melengkapi dalam proses klasifikasi (Napitu dkk., 2023). Dengan demikian, peningkatan performa pada



penelitian ini tidak hanya disebabkan oleh penggunaan citra bersih, tetapi juga oleh adanya informasi warna eksplisit dari RGB-HSV yang melengkapi fitur mendalam yang dipelajari oleh *ResNet50*. Integrasi karakteristik warna dan pola visual juga telah digunakan dalam klasifikasi cabai berbasis CNN untuk membantu membedakan karakteristik antarobjek cabai (Rohman dkk., 2024).

Penggabungan fitur mendalam *ResNet50* dengan fitur warna RGB-HSV melalui pendekatan *hybrid feature fusion* menghasilkan representasi fitur yang lebih komprehensif karena masing-masing jalur memberikan informasi yang berbeda. Fitur *ResNet50* berkontribusi dalam mengenali pola visual kompleks secara otomatis, sedangkan fitur RGB-HSV memberikan informasi warna secara eksplisit sebelum kedua jenis fitur tersebut digabungkan pada tahap *fusion*. Pendekatan penggabungan fitur tersebut sejalan dengan konsep *hybrid feature fusion* yang menunjukkan bahwa integrasi beberapa jenis fitur dapat meningkatkan kemampuan model dalam mengenali karakteristik visual tanaman cabai (Tiwari dkk., 2025). Hasil penelitian terdahulu juga menunjukkan bahwa metode berbasis CNN mampu memberikan performa tinggi dalam klasifikasi kematangan cabai, baik melalui kombinasi CNN dan *K-Nearest Neighbor* maupun menggunakan arsitektur *LeNet-5* dan *MobileNet-V2* (Hadi dkk., 2025; Ulum dkk., 2024). Meskipun demikian, hasil prediksi terhadap 10 citra di luar *dataset* masih menghasilkan dua kesalahan klasifikasi, yang menunjukkan bahwa kesamaan karakteristik visual antar kategori masih dapat menyebabkan model salah membedakan kelas. Kondisi tersebut menunjukkan bahwa pendekatan *hybrid feature fusion* mampu meningkatkan performa klasifikasi, tetapi kemampuan generalisasi model masih perlu diperkuat menggunakan citra dengan variasi karakteristik visual yang lebih luas.

4. KESIMPULAN

Penelitian ini menggunakan total 1.592 citra cabai yang terdiri dari 416 citra kategori *Hot*, 514 citra kategori *Medium*, dan 662 citra kategori *Mild*. *Dataset* tersebut kemudian dibagi dengan rasio 70:15:15, yaitu 1.114 citra sebagai data *training*, 239 citra sebagai data *validation*, dan 239 citra sebagai data *testing*. Berdasarkan hasil penelitian, pendekatan *hybrid feature fusion* dengan menggabungkan arsitektur *ResNet50*, citra hasil penghapusan *background*, serta fitur warna RGB dan HSV mampu meningkatkan performa klasifikasi tingkat kepedasan cabai ke dalam tiga kategori, yaitu *Hot*, *Medium*, dan *Mild*. Model dengan *input* citra bersih yang dikombinasikan dengan fitur RGB-HSV memperoleh hasil lebih baik dibandingkan model yang hanya menggunakan citra asli. Model citra bersih dengan RGB-HSV menghasilkan *accuracy* 96,23%, *precision* 96,10%, *recall* 96,08%, dan *f1-score* 96,08%, sedangkan model citra asli memperoleh *accuracy* 87,03%, *precision* 87,21%, *recall* 86,90%, dan *f1-score* 86,96%. Hasil tersebut menunjukkan bahwa penghapusan *background* mampu mengurangi gangguan dari latar belakang citra, sedangkan fitur warna RGB-HSV memberikan informasi tambahan yang membantu model membedakan karakteristik visual cabai. Meskipun demikian, penelitian ini masih memiliki keterbatasan, yaitu jumlah *dataset* pada setiap kelas belum sepenuhnya seimbang, kategori kepedasan hanya dibatasi pada tiga kelas, dan penentuan label masih mengacu pada karakteristik visual warna yang disesuaikan dengan *Scoville Level* tanpa pengujian SHU secara langsung. Selain itu, pengujian prediksi eksternal masih terbatas pada 10 sampel citra dari *internet*, sehingga kemampuan generalisasi model terhadap variasi pencahayaan, sudut pengambilan gambar, latar belakang, dan jenis cabai lain masih perlu diteliti lebih lanjut. Penelitian selanjutnya dapat dikembangkan dengan menambah jumlah serta variasi *dataset*, melakukan validasi tingkat kepedasan berbasis pengukuran SHU, menerapkan augmentasi data yang lebih beragam, serta membandingkan performa *ResNet50* dengan arsitektur lain agar sistem klasifikasi menjadi lebih akurat dan stabil.

Kontribusi ilmiah penelitian ini terletak pada penerapan pendekatan *hybrid feature fusion* yang mengintegrasikan fitur mendalam *ResNet50* dengan fitur warna RGB-HSV untuk klasifikasi indikasi tingkat kepedasan cabai berdasarkan karakteristik visual. Pendekatan tersebut menghasilkan representasi fitur yang lebih kaya karena *ResNet50* menangkap pola visual kompleks, sedangkan RGB-HSV memberikan informasi warna secara eksplisit. Peningkatan performa model menunjukkan bahwa kombinasi fitur mendalam dan fitur warna dapat menjadi alternatif yang efektif dalam pengembangan metode klasifikasi citra berbasis *deep learning*. Secara praktis, pendekatan ini berpotensi digunakan sebagai dasar pengembangan sistem klasifikasi dan penyortiran cabai berbasis *computer vision* yang lebih objektif, konsisten, dan efisien.

REFERENCES

- Badan Pusat Statistik. (2026, Mei 25). *Produksi tanaman sayuran dan buah-buahan semusim menurut provinsi dan jenis tanaman*, 2025. <https://www.bps.go.id/id/statistics-table/3/ZUhFd1JtZzJWVWpqWTJsV05XTllhVmhmRSzFoNFFUMDkjMw%3D%3D/produksi-tanaman-sayuran.html>
- Cini. (2025). *The Heat Is On: A Beginner's Guide to Understanding Scoville Levels*. Cini Sauce. <https://cinisauce.com/the-heat-is-on-a-beginners-guide-to-understanding-scoville-levels/>
- Gatis, D. (2026). *rembg* (Version 2.0.75). GitHub. <https://github.com/danielgatis/rembg>
- Hadi, R., Dwiyanaputra, R., & Irfan, P. (2025). Implementasi *LeNet-5* dan *MobileNet-V2* untuk Klasifikasi Kematangan Buah Cabai Berbasis Computer Vision. *Jurnal Mahasiswa Teknik Informatika*, 9(1). <https://doi.org/10.36040/jati.v9i1.12725>



- Irma, I., Muchtar, M., Adawiyah, R., & Sarimuddin, S. (2024). Klasifikasi Tingkat Kematangan Cabai Merah Keriting Menggunakan SVM Multiclass Berdasarkan Ekstraksi Fitur Warna. *Jurnal Informatika dan Teknik Elektro Terapan*, 12(3), 1747–1755. <https://doi.org/10.23960/jitet.v12i3.4430>
- Kamilah, A., & Fatah, Z. (2024). Klasifikasi Kematangan Tanaman Cabai Menggunakan Teachable Machine: Pendekatan Berbasis Gambar. *Jurnal Sains dan Sistem Teknologi Informasi*, 6(2), 30–41. <https://doi.org/10.59811/9anvvc21>
- Kaswar, A. B., Adiba, F., & Andayani, D. D. (2023). Sistem Klasifikasi Tingkat Kematangan Buah Cabai Katokkon Berdasarkan Fitur Warna LAB Menggunakan Artificial Neural Network Backpropagation. *Journal of Embedded Systems, Security and Intelligent Systems*, 4(2), 149–157. <https://doi.org/10.59562/jessi.v4i2.996>
- Mahdiyah, U. (2023). Klasifikasi Kualitas Citra Cabai dengan Menggunakan Algoritma Gradien Boosting. *JAMI: Jurnal Ahli Muda Indonesia*, 4(1), 61–69. <https://doi.org/10.46510/jami.v4i1.137>
- Mujidah, M., & Agustin, S. (2024). Klasifikasi Kualitas Biji Kopi Robusta Menggunakan Metode K-Nearest Neighbor (K-NN) Dan Gray Co-Occurance Matrix (GLCM). *JATI (Jurnal Mahasiswa Teknik Informatika)*, 8(6), 11832–11838. <https://doi.org/10.36040/jati.v8i6.11721>
- Napitu, S., Paramita Panjaitan, R., Nulhakim, P. A., & Khalik Lubis, M. (2023). Klasifikasi Buah Jeruk Segar dan Busuk Berdasarkan RGB dan HSV Menggunakan Metode KNN. *Jurnal SAINTEKOM*, 13(2), 214–221. <https://doi.org/10.33020/saintekom.v13i2.420>
- Ningrum, B. N. T. C., Ni'mah, E. N., Arifin, M. P., & Dara, M. A. D. W. (2024). Klasifikasi dan Pengenalan Pola Penyakit Cabai dengan Metode CNN (Convolution Neural Network). *Prosiding Seminar Nasional Teknologi dan Sains*, 3(1), 125–132. <https://doi.org/10.29407/stains.v3i1.4137>
- Noviana, M., & Sudiro, S. A. (2024). Automation of the BERT and RESNET50 Model Inference Configuration Analysis Process. *JITK (Jurnal Ilmu Pengetahuan dan Teknologi Komputer)*, 10(2), 324–332. <https://doi.org/10.33480/jitk.v10i2.5053>
- Permata, E., & Ramadhanu, A. (2025). Klasifikasi Bawang Merah, Bawang Putih, dan Tomat Dengan Hybrid Intelligence System Berbasis KNN dan PCA. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 9(2), 3616–3621. <https://doi.org/10.36040/jati.v9i2.13559>
- Pusat Data dan Sistem Informasi Pertanian. (2025). *Buletin Konsumsi Pangan 2025* (1 ed., Vol. 16). Kementerian Pertanian Republik Indonesia.
- Rohman, R. A., Dasuki, M., Muharom, L. A., & Rahman, M. (2024). Penerapan Algoritma Convolution Neural Network untuk Klasifikasi Jenis Cabai Berdasarkan Warna dan Bentuk Buah. *Jurnal Informatika dan Rekayasa Perangkat Lunak*, 6(2), 345–351.
- Sujaka, T. T., Switrayana, N., Mumtaz, I., & Fillah, H. (2025). Pengaplikasian Convolutional Neural Network (MobileNetV3) Memanfaatkan Transfer Learning Untuk Membedakan Tanaman Cabai Berasal Dari Genus Capsicum Annuum. *Technology and Science (BITS)*, 7(3), 1761–1774. <https://doi.org/10.47065/bits.v7i3.8740>
- Tiwari, R. G., Nyamasvisva, T. E., Ibrahim, N., Dixit, A., Trivedi, N. K., & Kumar, A. (2025). Hybrid Feature Fusion and Deep Learning for High-Accuracy Anthracnose Detection in Chili Plants. *Journal of Innovative Image Processing*, 7(3), 602–621. <https://doi.org/10.36548/jiip.2025.3.002>
- Ulum, M. R. B., Rahmat, B., & Swari, M. H. P. (2024). Implementasi Metode CNN Dan K-Nearest Neighbor Untuk Klasifikasi Tingkat Kematangan Tanaman Cabai Rawit. *Jurnal Informatika dan Sains Teknologi*, 1(3), 112–123. <https://doi.org/10.62951/modem.v1i3.131>
- Wasilah, Q. S. A., Martanto, M., Rinaldi Dikananda, A., & Rohman, D. (2025). Implementasi CNN ResNet50 untuk Mendeteksi Kualitas Buah dan Sayuran di Pasar Tradisional. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 9(3), 3675–3682. <https://doi.org/10.36040/jati.v9i3.13349>