



Perbandingan SVM dan CNN *MobileNetV2* untuk klasifikasi residu insektisida pada citra buah kakao

Rahmawati, Nurhikma Arifin, Wawan Firgiawan

Program Studi Informatika, Fakultas Teknik, Universitas Sulawesi Barat, Indonesia

Article history:

Diterima 1 April 2026

Direvisi 30 April 2026

Disetujui 30 April 2026

Keywords:

Kakao

Residu insektisida

Klasifikasi citra

Support Vector Machine

Convolutional Neural Network

ABSTRACT. The decline in cocoa production in West Sulawesi due to pest attacks and the use of insecticides that leave residues on the fruit surface has reduced visual quality and highlights the need for efficient automatic classification based on digital image processing. This study aims to classify cocoa fruit images into three classes (Normal, Insecticide-Treated, and Residue) and to compare the performance of Support Vector Machine (SVM) and Convolutional Neural Network (CNN) with the MobileNetV2 architecture. The dataset consists of 672 images divided into training and testing sets with an 80:20 ratio and evaluated under two training data conditions: imbalanced and balanced through rotation-based augmentation at an image size of 224×224 pixels. For SVM, color and texture features are extracted using Hue Saturation Value (HSV) and Local Binary Pattern (LBP), while the CNN model adopts MobileNetV2 with transfer learning and an adjusted fully connected layer. The results show that SVM with combined HSV and LBP features achieves an accuracy of 86.67%, whereas CNN attains 82.22% on data without augmentation and improves to 87.41% on augmented data. The McNemar test on the same test set yields p-values of 0.6171 and 1.0000 for the imbalanced and balanced training data conditions, indicating that the performance difference between the two methods is not statistically significant and that both models provide comparable classification capability.

ABSTRAK. Penurunan produksi kakao di Sulawesi Barat akibat serangan hama dan penggunaan insektisida yang meninggalkan residu pada permukaan buah menurunkan kualitas visual dan menunjukkan perlunya metode klasifikasi otomatis berbasis pengolahan citra digital yang efisien. Penelitian ini bertujuan mengklasifikasikan citra buah kakao ke dalam tiga kelas (Normal, Berinsektisida, dan Residu) serta membandingkan kinerja *Support Vector Machine* (SVM) dan *Convolutional Neural Network* (CNN) dengan arsitektur MobileNetV2. Dataset terdiri atas 672 citra yang dibagi menjadi data latih dan data uji dengan rasio 80:20 dan dievaluasi pada dua kondisi data latih, yaitu tidak seimbang dan seimbang melalui *augmentasi* rotasi dengan ukuran citra 224×224 piksel. Pada SVM, fitur warna dan tekstur diekstraksi menggunakan *Hue Saturation Value* (HSV) dan *Local Binary Pattern* (LBP), sedangkan CNN menggunakan MobileNetV2 dengan pendekatan *transfer learning* dan penyesuaian *fully connected layer*. Hasil pengujian menunjukkan bahwa SVM dengan kombinasi fitur HSV dan LBP mencapai akurasi 86,67%, sedangkan CNN memperoleh akurasi 82,22% pada data tanpa *augmentasi* dan meningkat menjadi 87,41% pada data setelah *augmentasi*. Uji McNemar pada data uji yang sama menghasilkan nilai *p-value* 0,6171 dan 1,0000 untuk kondisi data latih tidak seimbang dan seimbang, yang menunjukkan bahwa perbedaan performa kedua metode tidak signifikan secara statistik sehingga keduanya memiliki kemampuan klasifikasi yang relatif sebanding.

This is an open-access article under the CC-BY-SA license.



Corresponding Author:

Rahmawati,

Fakultas Teknik, Universitas Sulawesi Barat,

Jl. Prof. Dr. Baharuddin Lopa, Majene, Sulawesi Barat, Indonesia

Email: rhmawthy.amma18024@gmail.com

PENDAHULUAN

Kakao (*Theobroma cacao L.*) merupakan komoditas perkebunan penting yang berperan besar dalam perekonomian Indonesia, karena menjadi salah satu penyumbang devisa negara serta sumber pendapatan bagi masyarakat pedesaan (Pertiwi *et al.*, 2021). Biji kakao Indonesia dikenal memiliki kualitas tinggi karena didukung oleh kondisi iklim yang sesuai, terutama di wilayah Sulawesi Barat yang termasuk dalam lima provinsi penghasil kakao terbesar di Indonesia (Arsyad *et al.*, 2023). Namun, dalam beberapa tahun terakhir, luas lahan dan produksi kakao di Sulawesi Barat mengalami penurunan, dari 84.429 ton pada tahun 2016 menjadi 71.374 ton pada tahun 2019, meskipun sedikit meningkat menjadi 74.172 ton pada tahun 2020 (Sulkadri *et al.*, 2022). Penurunan produksi tersebut antara lain disebabkan oleh tingginya serangan hama dan penyakit pada tanaman kakao, seperti penggerek buah kakao (PBK) dan *Vascular Streak Dieback* (VSD), yang berdampak pada menurunnya produktivitas serta kualitas kakao di Sulawesi Barat (Indrayana, 2021).

Salah satu hama utama yang menjadi penyebab penurunan produksi kakao adalah penggerek buah kakao (PBK) (*Conopomorpha cramerella* Snellen), yang diketahui dapat menurunkan hasil produksi kakao dengan kisaran antara 18,25% hingga 73,04% (Lea *et al.*, 2024). Untuk menanggulangi serangan tersebut, petani biasanya melakukan pengendalian menggunakan teknik oles dengan formulasi insektisida pada alur buah kakao secara vertikal. Penelitian menunjukkan bahwa metode ini memberikan hasil terbaik, dengan tingkat serangan hanya 1,29% (Pertiwi *et al.*, 2021). Namun, residu insektisida yang menempel pada buah dapat menurunkan kualitas visual, serta berdampak negatif terhadap kesehatan petani, konsumen, dan lingkungan (Wisnujatia & Sangadji, 2021). Keberadaan residu ini menjadi masalah serius karena dapat bertahan pada permukaan buah dan berpotensi terakumulasi, sehingga meningkatkan risiko paparan pestisida dan pencemaran lingkungan (Jamin *et al.*, 2024). Dalam praktik di lapangan, identifikasi kondisi buah kakao Normal, Berinsektisida, dan Residu masih banyak mengandalkan pengamatan visual manual yang bersifat subjektif, bergantung pada pengalaman, dan memerlukan waktu, sehingga diperlukan pendekatan klasifikasi otomatis yang lebih objektif dan efisien.

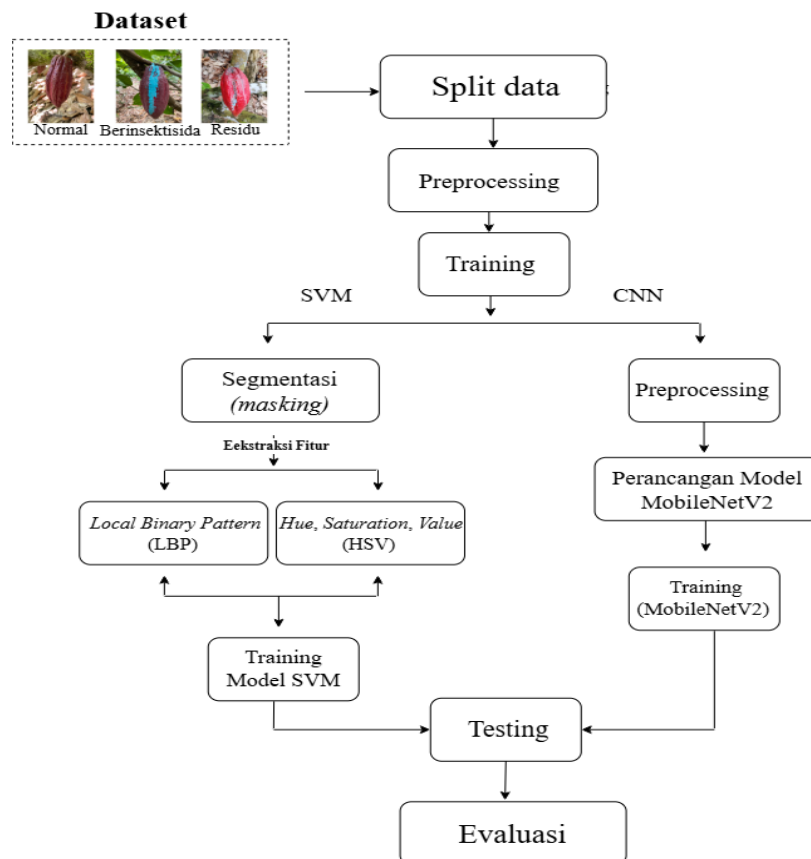
Hingga saat ini, telah banyak penelitian yang menerapkan teknik pengolahan citra digital untuk klasifikasi penyakit buah kakao berdasarkan karakteristik visualnya (Novanto *et al.*, 2025). Di sisi lain, beberapa studi lebih banyak berfokus pada efektivitas penggunaan insektisida dan pengendalian hama penggerek buah kakao (PBK) (Pertiwi *et al.*, 2021; Lea *et al.*, 2024). Namun, penelitian tersebut masih terbatas pada aspek pengendalian hama dan belum secara spesifik mengkaji klasifikasi citra buah kakao berdasarkan pengaruh residu insektisida pada permukaan buah. Oleh karena itu, masih terdapat kesenjangan dalam pemanfaatan pengolahan citra digital untuk mengklasifikasikan buah kakao ke dalam kategori Normal, Berinsektisida, dan Residu.

Beberapa penelitian terdahulu menunjukkan efektivitas metode ekstraksi fitur dan algoritma klasifikasi dalam pengenalan citra. Neneng *et al.* (2021) membandingkan metode GLCM dan LBP dengan algoritma SVM dan memperoleh akurasi tertinggi 85,6% pada LBP, lebih tinggi dibanding GLCM sebesar 75,6%. Selanjutnya, Neneng *et al.* (2020) menunjukkan akurasi tinggi sebesar 91,3% menggunakan metode LBP dan SVM pada klasifikasi jenis kayu. Penelitian lainnya menyimpulkan bahwa ruang warna HSV memberikan kualitas citra yang lebih baik dibandingkan ruang warna YCbCr maupun RGB (Citra & Kembung, 2022), dan Rabbani *et al.* (2021) menunjukkan akurasi 99,2% menggunakan kombinasi fitur RGB–HSV serta 98,4% pada kombinasi LBP–warna. Fatimah & Agustin (2025) dalam klasifikasi citra batik menggunakan LBP dan SVM memperoleh akurasi 88,98% dengan variasi nilai *precision*, *recall*, dan *F1-score*. Selain itu, Hamzah *et al.* (2024) menunjukkan akurasi tertinggi 86,67% menggunakan SVM dalam klasifikasi kematangan buah alpukat, lebih tinggi dibandingkan KNN. Berdasarkan temuan tersebut, kombinasi fitur tekstur LBP dan warna HSV dengan algoritma SVM terbukti mampu memberikan akurasi tinggi dalam klasifikasi citra, sehingga relevan digunakan dalam penelitian ini untuk mengklasifikasikan buah kakao Normal, Berinsektisida, dan Residu secara akurat dan efisien.

Sebagian besar penelitian sebelumnya masih menggunakan ekstraksi fitur manual dan algoritma *machine learning* seperti *Support Vector Machine* (SVM), sementara pendekatan *deep learning* seperti *Convolutional Neural Network* (CNN) mampu meningkatkan efisiensi dan akurasi klasifikasi (Suandana & Apriandari, 2024). Penelitian lain menunjukkan bahwa CNN mencapai akurasi 90,87%, lebih tinggi dibandingkan SVM pada dataset Kaggle yang terdiri dari 11.219 sampel dan 17 kategori (Kurniadi *et al.*, 2021). MobileNetV2 sebagai salah satu arsitektur CNN yang efisien memanfaatkan *depthwise separable convolution*, *inverted residual block*, dan *linear bottleneck*, sehingga cocok digunakan pada perangkat dengan sumber daya komputasi terbatas dan aplikasi lapangan (Widyana *et al.*, 2026; Dharojat *et al.*, 2026). Berdasarkan hal tersebut, penelitian ini bertujuan untuk membandingkan kinerja metode *Support Vector Machine* (SVM) dan *Convolutional Neural Network* (CNN) dengan arsitektur MobileNetV2 dalam mengklasifikasikan citra buah kakao ke dalam tiga kelas, yaitu Normal, Berinsektisida, dan Residu, berdasarkan nilai *accuracy*, *precision*, *recall*, dan *F1-score*. CNN memiliki potensi menghasilkan performa lebih tinggi karena mampu mengekstraksi fitur secara otomatis dari citra, sedangkan SVM memberikan hasil yang lebih stabil pada dataset berukuran terbatas. Oleh karena itu, penelitian ini diharapkan dapat menentukan metode klasifikasi yang paling optimal untuk mendukung identifikasi kualitas buah kakao secara cepat dan akurat.

METODE

Metode penelitian dimulai dengan pengumpulan citra buah kakao Normal, Berinsektisida, dan Residu yang kemudian dibagi menjadi data *training* dan *testing*. Model dikembangkan menggunakan metode SVM dengan fitur LBP dan HSV serta CNN dengan arsitektur MobileNetV2. Selanjutnya dilakukan pengujian dan evaluasi untuk membandingkan kinerja kedua metode. Alur penelitian ditunjukkan pada Gambar 1.



Gambar 1. Alur penelitian

Dataset

Data yang digunakan pada penelitian ini merupakan data primer yang diperoleh dari Desa Riso, Kecamatan Tapango, Kabupaten Polewali Mandar, Sulawesi Barat, dengan jumlah total 672 citra kakao dengan kondisi berbeda. Data ini terdiri dari tiga kategori, yaitu 231 Normal, 239 Berinsektisida, dan 202 Residu. Contoh citra dari masing-masing kelas dapat dilihat pada Gambar 2.



Gambar 2. Contoh dataset kakao

Split Data

Data citra kakao dibagi menjadi dua bagian, yaitu data latih (*training*) dan data uji (*testing*) dengan rasio 80:20 menggunakan metode *stratified split*, sehingga proporsi setiap kelas tetap terjaga. Data latih digunakan untuk membangun model, sedangkan data uji digunakan untuk mengevaluasi kinerja model. Dari total 672 citra, diperoleh 537 data latih dan 135 data uji. Distribusi data menunjukkan bahwa kelas Berinsektisida terdiri dari 191 data latih dan 48 data uji, kelas Normal terdiri dari 185 data latih dan 46 data uji, serta kelas Residu terdiri dari 161 data latih dan 41 data uji.

Preprocessing


Pada tahap *preprocessing*, seluruh citra diubah ukurannya menjadi 224×224 piksel. Keseimbangan data pada data latih diatasi melalui *augmentasi* menggunakan transformasi rotasi dengan sudut acak dalam rentang -30° hingga 30° hingga distribusi data menjadi seimbang, yaitu 198 citra per kelas, yang juga menghasilkan variasi citra baru untuk membantu model mempelajari pola yang lebih beragam. Secara rinci, kelas Normal mengalami penambahan 13 citra, kelas Residu 37 citra, dan kelas Berinsektisida 7 citra, sehingga jumlah data latih meningkat dari 537 menjadi 594 citra. Selain itu, pada pelatihan model CNN diterapkan *augmentasi* tambahan berupa rotasi hingga 20° , *zoom* sebesar 0,2, dan *horizontal flipping*.

Segmentasi

Proses segmentasi (*masking*) dilakukan untuk memisahkan objek buah kakao dari latar belakang sehingga ekstraksi fitur hanya berfokus pada area objek saja. Tahapan ini diawali dengan konversi citra ke ruang warna HSV untuk mempermudah pemisahan berdasarkan karakteristik warna. Selanjutnya dilakukan *binary masking* pada kanal *Hue* (H), *Saturation* (S), dan *Value* (V) sehingga diperoleh citra biner dengan objek buah berwarna putih dan latar belakang hitam. Nilai *lower* dan *upper threshold* HSV ditentukan secara empiris menggunakan metode *trial-and-error*, kemudian ditingkatkan melalui operasi morfologi untuk mengurangi *noise*. Nilai *threshold* yang digunakan pada masing-masing kelas ditampilkan pada Tabel 1, sedangkan hasil visualisasi proses segmentasi buah kakao dapat dilihat pada Gambar 3.

Table 1. Nilai *Lower dan Upper* HSV

	Masking 1	Masking 2	Masking 3
<i>Lower</i>	[0, 69, 62]	[114, 29, 43]	[96, 85, 83]
<i>Upper</i>	[11, 244, 255]	[179, 255, 255]	[179, 255, 255]



Gambar 3. Visualisasi hasil segmentasi

Ekstraksi Fitur

Ekstraksi fitur dilakukan untuk mengambil informasi warna dari HSV dan tekstur dari LBP. Kedua fitur ini digabungkan agar model memiliki informasi yang lebih lengkap untuk diklasifikasikan.

Fitur Warna HSV

Model HSV merepresentasikan warna lebih sesuai dengan persepsi visual manusia dibandingkan model RGB, di mana *Hue* menunjukkan jenis warna, *Saturation* tingkat kejenuhan, dan *Value* tingkat kecerahan (Rabbani *et al.*, 2021). Sebelum proses konversi ke ruang warna HSV, nilai RGB (*red, green, blue*) terlebih dahulu dinormalisasi untuk mengubah rentang nilai dari 0–255 menjadi 0–1. Proses ini bertujuan untuk mengurangi pengaruh variasi intensitas pencahayaan serta menjaga konsistensi skala data. Normalisasi RGB dilakukan menggunakan persamaan (1).

$$\mathbf{r} = \frac{R}{255}, \quad \mathbf{g} = \frac{G}{255}, \quad \mathbf{b} = \frac{B}{255} \quad (1)$$

Setelah proses normalisasi dilakukan, nilai RGB yang telah dinormalisasi kemudian dikonversi ke dalam ruang warna HSV menggunakan persamaan yang ditunjukkan pada persamaan (2), (3), dan (4). Dengan H , S , dan V masing-masing merupakan komponen *Hue*, *Saturation*, dan *Value*; r , g , dan b adalah nilai RGB yang telah dinormalisasikan; serta \max dan \min adalah nilai maksimum dan minimum dari r , g , dan b .


$$V = \max(r, g, b) \quad (2)$$

$$S = \begin{cases} 0, & \text{jika } V = 0 \\ \left(\frac{\max - \min}{\max}\right), & \text{jika lainnya} \end{cases} \quad (3)$$

$$H = \begin{cases} S = 0, H = 0 \\ 60^\circ x = \left(\frac{G-B}{\max - \min} \bmod 6\right), & \max = r \\ 60^\circ x = \left(\frac{G-B}{\max - \min} + 2\right), & \max = g \\ 60^\circ x = \left(\frac{G-B}{\max - \min} + 4\right), & \max = b \end{cases} \quad (4)$$

Fitur Tekstur LBP

Metode *Local Binary Pattern* (LBP) digunakan untuk merepresentasikan tekstur pada citra digital, termasuk tekstur permukaan buah kakao. Seperti ditunjukkan pada Gambar 4, LBP bekerja dengan membandingkan nilai intensitas piksel pusat dengan piksel di sekitarnya dalam jendela lokal, umumnya 3×3 , yang terdiri dari 8 piksel tetangga dengan radius 1. Piksel tetangga yang memiliki intensitas lebih tinggi dari piksel pusat diberi nilai 1, sedangkan yang lebih rendah diberi nilai 0.



Gambar 4. Grafis *Local Binary Pattern*

Pada penelitian ini, ekstraksi fitur LBP dilakukan menggunakan metode *uniform* dengan variasi radius $R = 1, 2$, dan 3 serta titik *sampling* $P = 8R$. Histogram LBP dari setiap kombinasi parameter dinormalisasi dan digabungkan sehingga menghasilkan total 54 fitur. Proses perbandingan ini dirumuskan pada persamaan (5), di mana P adalah jumlah titik *sampling*, R adalah radius, g_c merupakan intensitas piksel pusat, dan g_p adalah intensitas piksel tetangga (Fatimah & Agustin, 2025). Dimana S dinyatakan pada persamaan (6).

$$LBP_{P,R} = \sum_{p=0}^{P-1} S(I_p - I_c) 2^p \quad (5)$$

dimana S dinyatakan pada persamaan (6) berikut :

$$S(x) = \begin{cases} 0, & \text{jika } x < 0 \\ 1, & \text{jika } x \geq 0 \end{cases} \quad (6)$$

Training Model SVM

Support Vector Machine (SVM) merupakan algoritma *supervised learning* yang bekerja dengan mencari *hyperplane* optimal untuk memisahkan kelas-kelas data dalam ruang fitur berdimensi tinggi (Chusna *et al.*, 2022). Perkembangan algoritma SVM terus mengalami peningkatan sehingga SVM dapat mengklasifikasikan beberapa kelas (*multiclass*) dengan memanfaatkan dua pendekatan utama, yaitu *One-vs-One* (OvO) dan *One-vs-All* (OvA). Fungsi keputusan dinyatakan pada persamaan (7) (Mughtar & Adawiyah, 2024).

$$f(x) = W^T x + b \quad (7)$$

Dengan $f(x)$ fungsi keputusan, W sebagai vektor bobot, x sebagai vektor fitur, dan b sebagai bias.



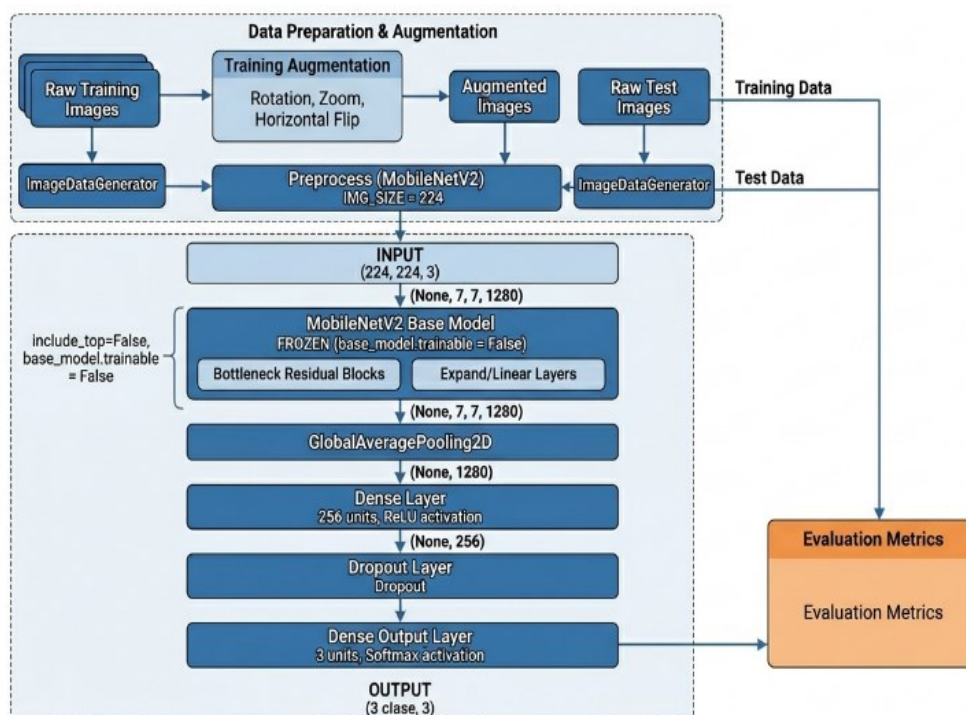
Gambar 5. *Hyperplane* sebelum optimasi Gambar 6. *Hyperplane* setelah optimasi

Support Vector Machine (SVM) bertujuan menentukan *hyperplane* yang memaksimalkan *margin* antar kelas. Seperti ditunjukkan pada Gambar 5 dan Gambar 6, posisi *hyperplane* berpengaruh terhadap hasil klasifikasi. *Hyperplane* yang tidak optimal menghasilkan *margin* yang kurang seimbang, sedangkan *hyperplane* yang optimal mampu memisahkan kelas dengan *margin* yang lebih baik sehingga meningkatkan akurasi klasifikasi (Fatimah & Agustin, 2025). Persamaan (8) menunjukkan fungsi optimasi SVM, di mana C sebagai parameter regulasi, y_i sebagai label kelas (-1 atau 1), dan x_i merupakan sampel data (Mughtar & Adawiyah, 2024).

$$\min_{w,b} = \frac{1}{2} ||w||^2 + C \sum_{i=1}^N \max(0, 1 - y_i(W^T x_i + b)) \quad (8)$$

Training Model CNN

Convolutional Neural Network (CNN) merupakan pengembangan dari *Multilayer Perceptron* (MLP) yang dirancang untuk mengolah data dua dimensi seperti citra. CNN terdiri dari beberapa lapisan utama, yaitu *convolutional layer* untuk ekstraksi fitur, *pooling layer* untuk reduksi dimensi, dan *fully connected layer* untuk proses klasifikasi (Suandana & Apriandari, 2024). Pada penelitian ini digunakan arsitektur MobileNetV2 sebagai model CNN karena memiliki efisiensi komputasi yang tinggi dengan tetap mempertahankan performa klasifikasi yang baik. MobileNetV2 merupakan pengembangan dari MobileNetV1 yang menerapkan konsep *inverted residual block* dan *linear bottleneck*, serta *depthwise separable convolution* sehingga lebih ringan dan cocok digunakan pada dataset dengan sumber daya terbatas (Widyana *et al.*, 2026; Dhorojat *et al.*, 2026). Ilustrasi struktur arsitektur MobileNetV2 ditunjukkan pada Gambar 7.



Gambar 7. Arsitektur MobileNetV2

Model dibangun menggunakan pendekatan *transfer learning* dengan bobot awal dari ImageNet dan parameter *include_top=False*. Lapisan akhir menggunakan *Global Average Pooling*, *fully connected layer* berukuran 256 neuron dengan aktivasi ReLU, *dropout* sebesar 0,5, serta *output layer* dengan 3 neuron dan aktivasi *softmax* untuk klasifikasi tiga kelas. Proses pelatihan (*training*) dilakukan menggunakan data latih yang telah melalui tahap *preprocessing* dan *augmentasi*. Model dilatih menggunakan *optimizer* Adam dengan *learning rate* 0,001, fungsi *loss categorical crossentropy*, dan metrik evaluasi akurasi. Selama pelatihan, bobot pada *base model* MobileNetV2 dibekukan (*frozen*) untuk mempertahankan fitur awal, sedangkan lapisan klasifikasi dilatih sesuai dengan dataset penelitian. Setelah proses pelatihan, model diuji (*testing*) menggunakan data uji tanpa *augmentasi* untuk mengevaluasi kemampuan generalisasi model terhadap data baru. Hasil pengujian kemudian digunakan untuk menghitung performa model berdasarkan metrik *accuracy*, *precision*, *recall*, dan *F1-score*.

Evaluasi

Tahap evaluasi dilakukan untuk menilai kinerja model menggunakan *confusion matrix* yang membandingkan hasil prediksi dengan label *actual*, sehingga diperoleh *true positive* (TP), *true*

negative (TN), *false positive* (FP), dan *false negative* (FN). Kinerja model diukur menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score*, di mana akurasi menunjukkan proporsi prediksi benar, *precision* mengukur ketepatan prediksi positif, *recall* mengukur kemampuan mendeteksi data positif, dan *F1-score* merupakan rata-rata harmonik antara *precision* dan *recall* (Fatimah & Agustin, 2025). Perhitungan metrik tersebut dinyatakan pada persamaan (9), (10), (11), dan (12).

$$Accuracy = \frac{\text{Jumlah Prediksi Benar}}{\text{Jumlah Total Data}} \times 100\% \quad (9)$$

$$Precision = \frac{\text{True Positive}}{\text{True Positive} + \text{False Negative}} \quad (10)$$

$$Recall = \frac{\text{True Positive}}{\text{True Positive} + \text{False Negative}} \quad (11)$$

$$F1 - Score = 2 \times \frac{(\text{Precision} \times \text{Recall})}{(\text{Precision} + \text{Recall})} \quad (12)$$

Selain menggunakan metrik evaluasi, penelitian ini juga menerapkan uji McNemar untuk menguji signifikansi perbedaan performa antara dua model pada data uji yang sama. Statistik uji McNemar dihitung berdasarkan nilai b dan c , yaitu jumlah data yang diklasifikasikan berbeda oleh kedua model. Nilai statistik tersebut digunakan untuk memperoleh p -value dengan derajat kebebasan (df) = 1. Jika p -value < 0,05, maka terdapat perbedaan yang signifikan, sedangkan jika p -value > 0,05, maka tidak terdapat perbedaan yang signifikan antara kedua model. Uji McNemar dengan koreksi kontinuitas dapat dilihat pada persamaan (13) (Wicaksono *et al.*, 2025).

$$\chi^2 = \frac{(|b-c|-1)^2}{b+c} \quad (13)$$

HASIL DAN DISKUSI

Pengumpulan Data

Data yang digunakan dalam penelitian ini merupakan data primer yang diperoleh dari Desa Riso, Kecamatan Tapango, Kabupaten Polewali Mandar, Sulawesi Barat. Proses pengambilan citra dilakukan menggunakan kamera ponsel Android dengan jarak fokus 4,20 mm dan resolusi gambar sebesar 3070 × 4096 piksel. Total data yang diperoleh sebanyak 672 citra buah kakao dengan kondisi yang berbeda, yang terdiri dari 231 citra kakao Normal, 239 citra kakao Berinsektisida, dan 202 citra kakao Residu.


Pelabelan Data

Pelabelan data dilakukan berdasarkan kondisi fisik buah kakao yang diamati di lapangan serta informasi dari petani dan hasil validasi Dinas Pertanian. Kakao Berinsektisida memiliki ciri berupa coretan insektisida yang tebal berwarna biru pada permukaan kulit buah. Kakao dengan Residu insektisida menunjukkan sisa lapisan insektisida yang tampak tipis dan memudar serta terdapat bercak hitam pada kulit buah. Sementara itu, kakao Normal memiliki permukaan kulit yang bersih dan seragam tanpa noda kimia bekas olesan insektisida.

Analisis Ekstraksi Fitur

Ekstraksi Fitur Warna HSV

Pada proses ekstraksi fitur warna digunakan ruang warna HSV (*Hue, Saturation, Value*). Citra RGB dikonversi ke ruang warna HSV untuk memperoleh informasi warna yang lebih representatif. Visualisasi pemisahan komponen HSV ditunjukkan pada Gambar 8. Sampel nilai hasil ekstraksi fitur HSV pada citra ditunjukkan pada Tabel 2, dengan kelas data Normal (0), Berinsektisida (1), dan Residu (2).




Gambar 8. Visualisasi ekstraksi fitur warna HSV

Tabel 2. Sampel nilai ekstraksi fitur HSV

No	Data	min H	min S	min V	Kelas
1	Normal	0.84524	0.46753	0.58128	0
2	Normal	0.32639	0.46870	0.40853	0
3	Normal	0.65318	0.39443	0.36112	0
4	Berinspektisida	0.29671	0.33584	0.42239	1
5	Berinspektisida	0.75652	0.42923	0.46170	1
6	Berinspektisida	0.51996	0.45925	0.55430	1
7	Residu	0.57273	0.33651	0.43817	2
8	Residu	0.36583	0.63415	0.58399	2
9	Residu	0.24902	0.33542	0.44123	2

Ekstraksi Fitur LBP (Local Binary Pattern)

Hasil transformasi citra menggunakan metode *Local Binary Pattern* (LBP) untuk mengekstraksi fitur tekstur ditunjukkan pada Gambar 9. Sampel nilai hasil ekstraksi fitur LBP dari beberapa citra ditampilkan pada Tabel 3 yang memuat nilai histogram LBP serta label kelas. Distribusi nilai histogram tersebut menunjukkan adanya perbedaan pola tekstur antar kelas, meskipun masih terdapat tumpang tindih pada beberapa rentang nilai, sehingga memerlukan algoritma klasifikasi yang mampu memanfaatkan kombinasi fitur warna dan tekstur secara efektif.



Gambar 9. Visualisasi ekstraksi fitur warna LBP

Tabel 3. Sampel nilai ekstraksi fitur LBP

No	Data	lbp_0	lbp_1	lbp_2	Lbp_53	Kelas
1	Normal	0.06803	0.08535	0.07167	...	0.44084	0
2	Normal	0.07800	0.08682	0.08039	...	0.47023	0
3	Normal	0.08821	0.09301	0.07823	...	0.53375	0
4	Berinspektisida	0.08104	0.09758	0.08003	...	0.40841	1
5	Berinspektisida	0.06382	0.08284	0.08339	...	0.42933	1
6	Berinspektisida	0.08623	0.09220	0.07329	...	0.48880	1
7	Residu	0.08859	0.09543	0.07665	...	0.45986	2
8	Residu	0.08726	0.08945	0.08045	...	0.47714	2
9	Residu	0.07699	0.09097	0.07695	...	0.45485	2

Hasil Klasifikasi Menggunakan SVM

Berdasarkan hasil pengujian yang telah dilakukan, metode klasifikasi menggunakan algoritma *Support Vector Machine* (SVM) menghasilkan akurasi sebesar 86,67% pada kombinasi fitur HSV dan LBP. *Confusion matrix* pada Tabel 4 menunjukkan bahwa sebanyak 43 data pada kelas Normal, 36 data pada kelas Berinsektisida, dan 38 data pada kelas Residu berhasil diklasifikasikan dengan benar. Namun demikian, masih terdapat beberapa kesalahan klasifikasi: pada kelas Normal, sebanyak 3 data salah diprediksi sebagai Berinsektisida; pada kelas Berinsektisida, sebanyak 8 data salah diprediksi sebagai Normal dan 4 data salah diprediksi sebagai Residu; sedangkan pada kelas Residu, terdapat 3 data yang salah diprediksi sebagai Berinsektisida. Kesalahan klasifikasi yang terjadi masih relatif kecil dan menunjukkan bahwa model SVM cukup baik dalam membedakan ketiga kelas.

Tabel 4. *Confusion Matrix* hasil pengujian SVM

Aktual\prediksi	Normal	Berinsektisida	Residu
Normal	43	3	0
Berinsektisida	8	36	4
Residu	0	3	38

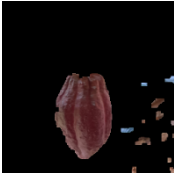

Pada Tabel 5 ditunjukkan perbandingan performa klasifikasi SVM berdasarkan metode ekstraksi fitur yang digunakan. Penggunaan fitur HSV menghasilkan akurasi sebesar 73,33%, sedangkan fitur LBP memberikan akurasi sebesar 76,30%. Sementara itu, kombinasi fitur HSV dan LBP mampu meningkatkan performa klasifikasi dengan akurasi mencapai 86,67%. Hal ini menunjukkan bahwa penggabungan fitur warna dan tekstur dapat memberikan informasi citra yang lebih lengkap sehingga meningkatkan kinerja model SVM dalam proses klasifikasi.

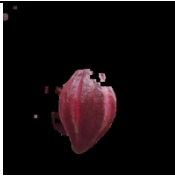
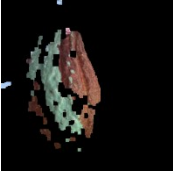
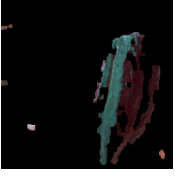
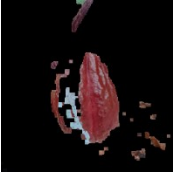
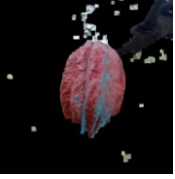

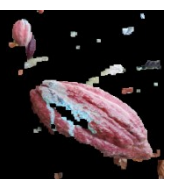
Tabel 5. Perbandingan performa klasifikasi SVM berdasarkan metode ekstraksi fitur

Metode	Accuracy	Precision	Recall	F1-score
SVM + HSV	73.33%	0.73	0.73	0.73
SVM + LBP	76.30%	0.76	0.76	0.76
SVM + HSV + LBP	86.67%	0.87	0.87	0.86

Selain itu, hasil prediksi setiap data uji ditampilkan pada Tabel 6 yang memuat file citra, label aktual, label prediksi, serta keterangan benar atau salah. Hasilnya menunjukkan bahwa sebagian besar citra berhasil diklasifikasikan dengan tepat oleh model SVM, meskipun masih terdapat beberapa kesalahan klasifikasi akibat kemiripan warna atau tekstur antar kelas, misalnya adanya bercak biru tipis atau garis hijau yang menyebabkan kakao Normal atau Residu terdeteksi sebagai Berinsektisida..

Tabel 6. Klasifikasi SVM berdasarkan metode ekstraksi fitur

File	Actual	Predicted	Keterangan
	0	1	Terdapat bercak biru akibat objek tertindih yang mempengaruhi hasil segmentasi.
	0	1	Permukaan kakao memiliki bercak garis hijau yang menyerupai kelas lain.

File	Actual	Predicted	Keterangan
	0	1	Secara visual, terdapat bercak garis hijau pada permukaan kakao yang menyebabkan kesalahan klasifikasi.
	1	2	Warna insektisida memudar sehingga terdeteksi sebagai kelas residu.
	1	0	Warna insektisida kurang dominan dan cenderung pudar sehingga menyerupai kakao normal dan menyebabkan kesalahan klasifikasi.
	1	0	Keberadaan coretan insektisida yang tidak dominan menyebabkan fitur menyerupai kakao normal.
	2	1	Terdapat bercak biru yang cukup jelas pada permukaan kakao sehingga teridentifikasi sebagai berinsektisida.
	2	1	Terdapat bagian latar belakang (batang kakao) yang ikut terambil dengan warna menyerupai insektisida.
	2	1	Segmentasi belum sempurna, masih terdapat sebagian latar belakang sehingga terjadi kesalahan klasifikasi.

Hasil Klasifikasi Menggunakan CNN

Hasil pengujian model CNN dengan arsitektur MobileNetV2 dievaluasi menggunakan data uji untuk mengetahui kemampuan model dalam mengklasifikasikan citra buah kakao. Hasil klasifikasi model CNN disajikan dalam bentuk *confusion matrix* pada Tabel 7.

Sebagian besar data berhasil diklasifikasikan dengan benar pada setiap kelas, yaitu 44 data Normal, 39 data Berinsektisida, dan 35 data Residu, sedangkan kesalahan klasifikasi utama terjadi pada kelas Residu, yaitu 3 data salah diklasifikasikan sebagai Normal dan 3 data sebagai Berinsektisida. Hal ini

menunjukkan bahwa model masih mengalami kesulitan dalam membedakan karakteristik visual kelas Residu dengan dua kelas lainnya yang memiliki kemiripan warna dan tekstur tertentu.

Tabel 7. *Confusion Matrix* hasil pengujian CNN

Aktual\prediksi	Normal	Berinesektisida	Residu
Normal	44	0	4
Berinesektisida	2	39	5
Residu	3	3	35

Pada eksperimen pertama, model CNN dilatih menggunakan dataset dengan distribusi kelas yang tidak seimbang (*imbalanced dataset*) tanpa penerapan teknik *augmentasi* data, sehingga seluruh proses pelatihan menggunakan data asli. Model menggunakan arsitektur MobileNetV2 dengan parameter pelatihan berupa *optimizer* Adam dengan *learning rate* sebesar 0,0001, *batch size* 16, serta fungsi *loss categorical crossentropy*. Hasil pelatihan model pada beberapa variasi epoch, yaitu 20, 30, dan 100, disajikan pada Tabel 8. Peningkatan jumlah epoch dari 20 ke 30 memberikan peningkatan performa yang cukup signifikan terutama pada *validation accuracy*, sedangkan peningkatan hingga 100 epoch menunjukkan kecenderungan konvergen, di mana peningkatan performa menjadi tidak signifikan.

Tabel 8. *Confusion Matrix* hasil pengujian CNN

Epoch	Training Accuracy	Validation Accuracy	Training Loss	Validation Loss
20	0.87	0.8222	0.3217	0.3743
30	0.91	0.8444	0.2559	0.3324
100	0.96	0.8593	0.1082	0.2931

Pada eksperimen kedua, dilakukan penyesuaian parameter pelatihan serta kondisi data latih untuk mengevaluasi pengaruhnya terhadap performa model. Perubahan yang dilakukan meliputi penggunaan *batch size* sebesar 32, peningkatan jumlah neuron pada *fully connected layer* menjadi 256, serta penggunaan *optimizer* Adam dengan *learning rate* sebesar 0,001. Selain itu, data latih disusun dengan distribusi kelas yang seimbang melalui *augmentasi* rotasi. Pengujian dilakukan dengan jumlah epoch yang sama, yaitu 20 epoch. Hasil pengujian menunjukkan bahwa model CNN memperoleh akurasi sebesar 82,22% pada data sebelum *augmentasi* dan meningkat menjadi 87,41% pada data setelah *augmentasi*, dengan pola *training* dan *validation accuracy* yang lebih stabil. Perbandingan performa model pada kedua eksperimen tersebut divisualisasikan pada Gambar 10.


Berdasarkan Gambar 10, terlihat bahwa model dengan data latih yang belum dilakukan *augmentasi* (kondisi tidak seimbang) menunjukkan pola *training accuracy* yang lebih tinggi dibandingkan *validation accuracy*, mengindikasikan adanya kecenderungan *overfitting*. Sebaliknya, model dengan data latih yang telah diaugmentasi menunjukkan pola *training* dan *validation accuracy* yang lebih stabil dan berdekatan, yang mengindikasikan kemampuan generalisasi model yang lebih baik.

Peningkatan performa CNN tidak hanya dipengaruhi oleh keseimbangan distribusi data latih, tetapi juga oleh penyesuaian parameter pelatihan seperti perubahan *learning rate*, *batch size*, dan arsitektur lapisan *fully connected*, yang secara bersama-sama berkontribusi dalam meningkatkan kemampuan generalisasi model.

Hasil Perbandingan Akurasi SVM dan CNN

Analisis hasil pengujian menunjukkan bahwa model CNN dan SVM memiliki performa yang relatif sebanding dalam mengklasifikasikan citra buah kakao. Metode CNN dengan arsitektur MobileNetV2 memperoleh akurasi sebesar 87,41%, sedangkan SVM menghasilkan akurasi sebesar 86,67%. Meskipun CNN menunjukkan nilai akurasi yang sedikit lebih tinggi, selisih performa antara kedua

metode relatif kecil, yaitu sekitar 0,74%. Untuk mengevaluasi signifikansi perbedaan tersebut, dilakukan uji McNemar yang hasilnya disajikan pada Tabel 9.



Gambar 10. Grafik perbandingan *training* dan *validation accuracy* serta *loss* *model CNN MobileNetV2 pada epoch ke-20: (a) sebelum augmentasi data latih (*learning rate 0,0001, batch size *16) dan (b) setelah augmentasi data latih (*learning rate 0,0001, batch size 16)

Tabel 9 memperlihatkan bahwa nilai *b* dan *c* merepresentasikan jumlah data yang salah diklasifikasikan oleh salah satu model namun benar oleh model lainnya, yaitu *b* adalah jumlah sampel yang benar pada CNN tetapi salah pada SVM, sedangkan *c* adalah jumlah sampel yang benar pada SVM tetapi salah pada CNN. Hasil pengujian menunjukkan nilai *p-value* sebesar 0,6171 pada kondisi data latih tidak seimbang (tanpa *augmentasi*) dan 1,0000 pada kondisi data latih seimbang (setelah *augmentasi*). Nilai *p-value* pada kedua kondisi tersebut lebih besar dari 0,05, sehingga tidak terdapat perbedaan yang signifikan secara statistik antara performa model CNN dan SVM.

Tabel 9. Hasil Uji McNemar antara CNN dan SVM

Kondisi Data Latih	<i>b</i>	<i>c</i>	statistik	<i>p – value</i>	Keterangan
Tidak seimbang	16	20	0.25	0.6171	Tidak signifikan
Seimbang	15	16	0.00	1.000	Tidak signifikan

Temuan ini mengindikasikan bahwa, meskipun CNN MobileNetV2 dengan data latih seimbang dan parameter pelatihan yang dioptimasi mampu mencapai akurasi sedikit lebih tinggi, metode SVM dengan kombinasi fitur HSV dan LBP tetap kompetitif dan dapat menjadi alternatif yang efisien pada kondisi sumber daya komputasi terbatas. Dengan demikian, pemilihan metode dapat disesuaikan dengan kebutuhan aplikasi: CNN lebih sesuai ketika tersedia kapasitas komputasi dan kebutuhan integrasi *end-to-end*, sementara SVM lebih menguntungkan pada skenario dengan dataset terbatas dan kebutuhan komputasi yang ringan.

KESIMPULAN

Penelitian ini berhasil mengklasifikasikan citra buah kakao ke dalam tiga kelas, yaitu Normal, Berinsektisida, dan Residu, menggunakan metode *Support Vector Machin* (SVM) dan *Convolutional Neural Network* (CNN) dengan arsitektur MobileNetV2. Hasil pengujian menunjukkan bahwa SVM dengan kombinasi fitur HSV dan LBP memperoleh akurasi sebesar 86,67%, sedangkan CNN memperoleh akurasi sebesar 82,22% pada data sebelum *augmentasi* dan meningkat menjadi 87,41% pada data setelah *augmentasi*. Temuan ini menunjukkan bahwa kedua metode mampu memberikan performa klasifikasi yang baik pada kasus klasifikasi residu insektisida pada citra buah kakao.

Berdasarkan hasil perbandingan, CNN MobileNetV2 memberikan akurasi tertinggi, tetapi selisih performanya terhadap SVM relatif kecil. Hasil uji McNemar menunjukkan bahwa perbedaan performa kedua metode tidak signifikan secara statistik, dengan nilai p -value sebesar 0,6171 pada kondisi data latih tidak seimbang dan 1,0000 pada kondisi data latih seimbang. Dengan demikian, SVM dengan kombinasi fitur HSV dan LBP tetap dapat menjadi alternatif yang efisien dan kompetitif, terutama pada kondisi dataset terbatas dan kebutuhan komputasi yang lebih ringan.

Hasil penelitian ini juga menunjukkan bahwa penyeimbangan data melalui *augmentasi* dan penyesuaian parameter pelatihan berperan penting dalam meningkatkan performa CNN. Oleh karena itu, pemilihan metode klasifikasi perlu disesuaikan dengan kebutuhan aplikasi, sumber daya komputasi, dan karakteristik data yang tersedia. Untuk penelitian selanjutnya, model dapat dikembangkan menggunakan dataset yang lebih besar dan lebih beragam, serta diuji dengan arsitektur *deep learning* lain atau skenario akuisisi citra lapangan yang lebih bervariasi agar diperoleh sistem klasifikasi yang lebih robust dan siap diterapkan secara praktis.

REFERENSI

- Arsyad, W., Mardiyanti, S., Nadir, N., Nailah, N., & Molla, S. (2023). Risiko produksi dan pendapatan usahatani kakao di Desa Kuajang Binuang Kabupaten Polewali Mandar. *Agricultural Socio-Economic Empowerment and Agribusiness Journal*, 1(2), 76–87. <https://doi.org/10.20961/agrisema.v1i2.64433>
- Chusna, N. L., Shalahudin, M. I., Riyanto, U., & Alexander, A. D. (2022). Klasifikasi citra jenis tanaman jamur layak konsumsi menggunakan algoritma multiclass support vector machine. *Building of Informatics, Technology and Science*, 4(1), 178–183. <https://doi.org/10.47065/bits.v4i1.1624>
- Citra, S., & Kembang, I. (2022). Perbandingan ruang warna RGB, HSV dan YCbCr untuk segmentasi citra ikan kembung menggunakan K-means clustering. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 6(2), 476–487. <https://doi.org/10.36040/jati.v6i2.4770>
- Dharajat, N. F. S., Furqonsyah, M. Y. C., Ghifary, F. M., & Ardiyanto, D. F. (2026). Perbandingan akurasi dan performa MobileNetV2 dan EfficientNetV2 untuk klasifikasi sampah. *JUSTIN (Jurnal Sistem dan Teknologi Informasi)*, 14(1), 16–22. <https://doi.org/10.26418/justin.v14i1.89086>
- Fatimah, N. S., & Agustin, S. (2025). Klasifikasi citra batik menggunakan Local Binary Pattern (LBP) dan Support Vector Machine (SVM). *Jurnal Algoritma*, 22(1), 185–196. <https://doi.org/10.33364/algoritma/v.22-1.2208>
- Hamzah, A., Susanti, E., & Lestari, R. M. (2024). Klasifikasi kematangan buah alpukat mentega berdasarkan fitur warna menggunakan Support Vector Machine (SVM). *Jurnal Innovation and Future Technology (IFTECH)*, 6(1), 108–120. <https://doi.org/10.47080/iftech.v2i2.1025>
- Indrayana, K. (2021). Akselerasi permasyarakatan teknologi produksi kakao mendukung peningkatan produktivitas komoditas ekspor di Sulawesi Barat. *Jurnal Agrisistem: Seri Sosek dan Penyuluhan*, 17(1), 16–25. <https://doi.org/10.52625/j-agr-sosekpenyuluhan.v17i1.179>
- Jamin, F. S., Mustofa, D., Restu, K., Rusli, M., & Adhi, S. (2024). Pesticide use in agriculture: Health risks and environmentally friendly alternatives. *Jurnal Kolaboratif Sains*, 7(11), 4151–4159. <https://doi.org/10.56338/jks.v7i11.6342>
- Kurniadi, B., Prasetyo, H., L. G. A., & Wibisono, B. A. (2021). Analisis perbandingan algoritma SVM dan CNN untuk klasifikasi buah. In *Prosiding Seminar Nasional Mahasiswa Ilmu Komputer dan Aplikasinya (SENAMIKA)* (Vol. 2, pp. 1–11). UPN Veteran Jakarta. <https://conference.upnvj.ac.id/index.php/senamika/article/view/1564>
- Lea, V. C., Hamakonda, U. A., Puspita, V. A., & Taus, I. (2024). Gerakan pengendalian organisme pengganggu tanaman kakao secara kimiawi di Kelompok Tani Kakao Desa Kisol Kabupaten Manggarai Timur. *ABDI UNISAP: Jurnal Pengabdian Kepada Masyarakat*, 2(2), 227–232. <https://doi.org/10.59632/abdiunisap.v2i2.317>
- Muchtar, M., & Adawiyah, R. (2024). Klasifikasi tingkat kematangan cabai merah keriting menggunakan SVM multiclass berdasarkan ekstraksi fitur warna. *JITE T (Jurnal Informatika dan Teknik Elektro Terapan)*, 12(3), 1747–1755. <https://doi.org/10.23960/jitet.v12i3.4430>
- Neneng, N., Putri, N. U., & Sari, E. R. (2020). Klasifikasi jenis kayu menggunakan Support Vector Machine berdasarkan ciri tekstur Local Binary Pattern. *CYBERNETICS*, 4(2), 93–100. <https://doi.org/10.29406/cbn.v4i02.2324>

- Neneng, N., Puspaningrum, A. S., & Aldino, A. A. (2021). Perbandingan hasil klasifikasi jenis daging menggunakan ekstraksi ciri tekstur Gray Level Co-occurrence Matrices (GLCM) dan Local Binary Pattern (LBP). *Smatika Jurnal*, 11(1), 48–52. <https://doi.org/10.32664/smatika.v11i01.572>
- Novanto, A., Kurniawan, Y. I., & Iskandar, D. (2025). Enhanced speed and accuracy in cocoa fruit disease identification using the Inception-ResNet Convolutional Neural Network (CNN) algorithm. *Jurnal Teknik Informatika (JUTIF)*, 6(1), 369–386. <https://doi.org/10.52436/1.jutif.2025.6.1.4144>
- Pertiwi, E. D., Megasari, R., & Taqwaluddin. (2021). Efektivitas teknik oles buah kakao menggunakan insektisida terhadap pengendalian hama PBK (*Conopomorpha cramerella* Snellen sp). *PERBAL (Pertanian Berkelanjutan)*, 9(2), 103–110. <https://doi.org/10.30605/perbal.v9i2.1580>
- Rabbani, H. A., Rahman, M. A., & Rahayudi, B. (2021). Perbandingan ruang warna RGB dan HSV dalam klasifikasi kematangan biji kopi. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 5(6), 2243–2248. <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/9013>
- Suandana, I. N., & Apriandari, W. (2024). Pemanfaatan CNN (Convolutional Neural Network) dan MobileNetV2 dalam klasifikasi rempah-rempah lokal di Indonesia. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 8(5), 10109–10116. <https://doi.org/10.36040/jati.v8i5.10873>
- Sulkadri, S., Ibrahim, B., & A. R. (2022). Evaluasi kesesuaian lahan tanaman kakao (*Theobroma cacao* L.) di Kecamatan Aralle Kabupaten Mamasa Provinsi Sulawesi Barat. *AGrotekMAS*, 3(3), 68–74. <https://doi.org/10.33096/agrotekmas.v3i3.269>
- Wicaksono, S. A., Utami, E., & Sari, T. I. (2025). Peningkatan akurasi deteksi penyakit malaria menggunakan transfer learning pada arsitektur CNN. *JUTISI: Jurnal Ilmiah Teknik Informatika dan Sistem Informasi*, 14(3), 2190–2198. <http://dx.doi.org/10.35889/jutisi.v14i3.3346>
- Widyana, K. R., Regasari, R., & Putri, M. (2026). Implementasi MobileNetV2 dan Support Vector Machine (SVM) untuk sistem sortir otomatis buah jeruk keprok berdasarkan tingkat kualitas. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 10(4), 1–11. <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/16287>
- Wisnujatia, N. S., & Sangadji, S. S. (2021). Pengelolaan penggunaan pestisida dalam mendukung pembangunan berkelanjutan di Indonesia. *SEPA: Jurnal Sosial Ekonomi Pertanian dan Agribisnis*, 18(1), 92–100. <https://doi.org/10.20961/sepa.v18i1.47297>