

Perbandingan Kinerja SVM, NN, Random Forest, dan KNN dalam Klasifikasi Tingkat Kematangan Buah Apel

Rahdian Kusuma Atmaja^{1*}, Ispandi², Rino Ramadan³, Oky Kurniawan⁴, Andi Taufik⁵

¹Program Studi Sistem Informasi (S1), Universitas Bina Sarana Informatika, Indonesia

^{2,5}Program Studi Informatika (S1), Universitas Bina Sarana Informatika, Indonesia

³Program Studi Sistem Informasi (D3), Universitas Bina Sarana Informatika, Indonesia

⁴Program Studi Teknologi Informasi (S1), Universitas Bina Sarana Informatika, Indonesia

^{1*}rahdian.kusuma@bsi.ac.id, ²Ispandi.ipd@bsi.ac.id, ³rino.rim@bsi.ac.id,

⁴oky.okw@bsi.ac.id, ⁵andi.iuf@bsi.ac.id

Abstrak: Penentuan tingkat kematangan buah apel secara visual masih rentan terhadap subjektivitas karena dipengaruhi oleh pengalaman pengamat, kondisi pencahayaan, dan kemiripan karakteristik antar tingkat kematangan. Penelitian ini bertujuan membandingkan kinerja Support Vector Machine (SVM), K-Nearest Neighbor (KNN), Neural Network (NN), dan Random Forest (RF) dalam mengklasifikasikan kematangan visual buah apel ke dalam tiga kelas, yaitu Belum Matang, Setengah Matang, dan Matang. Dataset terdiri atas 900 citra, masing-masing 300 citra per kelas, yang dibagi secara stratified menjadi 80% data latih dan 20% data uji. Tahap preprocessing meliputi resize citra menjadi 256 × 256 piksel, normalisasi, segmentasi objek, serta augmentasi pada data latih menggunakan horizontal flip, vertical flip, rotasi +15°, dan rotasi -15°. Fitur warna RGB, HSV, dan CIELAB, fitur tekstur GLCM, serta fitur bentuk digunakan sebagai masukan model. Optimasi hiperparameter dilakukan menggunakan stratified 5-fold cross-validation, sedangkan evaluasi menggunakan accuracy, precision, recall, dan F1-score. Hasil pengujian menunjukkan bahwa SVM memberikan performa terbaik dengan accuracy 95,0%, precision 94,8%, recall 94,6%, dan F1-score 94,7%, diikuti KNN dengan accuracy 94,0%, NN 92,8%, dan RF 91,2%. Hasil ini menunjukkan bahwa SVM merupakan metode paling sesuai pada dataset dan skenario pengujian yang digunakan, sedangkan KNN menjadi alternatif dengan performa yang paling mendekati. Penelitian selanjutnya disarankan memperluas variasi dataset dan menguji generalisasi model pada kondisi pengambilan citra yang lebih beragam.

Kata Kunci: Kematangan Apel; Klasifikasi Citra; Support Vector Machine; K-Nearest Neighbor; Neural Network; Random Forest.

Abstract: Visual determination of apple ripeness is still prone to subjectivity because it can be influenced by observer experience, lighting conditions, and similarities in visual characteristics between ripeness levels. This study aims to compare the performance of Support Vector Machine (SVM), K-Nearest Neighbor (KNN), Neural Network (NN), and Random Forest (RF) in classifying the visual ripeness of apples into three classes: Unripe, Half-Ripe, and Ripe. The dataset consists of 900 images, with 300 images for each class, and is stratified into 80% training data and 20% testing data. The preprocessing stage includes resizing the images to 256 × 256 pixels, normalization, object segmentation, and

augmentation of the training data using horizontal flip, vertical flip, +15° rotation, and -15° rotation. RGB, HSV, and CIELAB color features, GLCM texture features, and shape features are used as model inputs. Hyperparameter optimization is performed using stratified 5-fold cross-validation, while model performance is evaluated using accuracy, precision, recall, and F1-score. The results show that SVM achieves the best performance with 95.0% accuracy, 94.8% precision, 94.6% recall, and a 94.7% F1-score, followed by KNN with 94.0% accuracy, NN with 92.8%, and RF with 91.2%. These results indicate that SVM is the most suitable method for the dataset and testing scenario used, while KNN provides the closest alternative performance. Future research is recommended to expand dataset diversity and evaluate model generalization under more varied image acquisition conditions.

Keywords: Apple Ripeness; Image Classification; Support Vector Machine; K-Nearest Neighbor; Neural Network; Random Forest.

1. PENDAHULUAN

Kematangan merupakan salah satu faktor penting yang menentukan mutu buah karena berkaitan dengan rasa, tekstur, kesegaran, daya simpan, serta nilai jual. Tingkat kematangan yang tidak sesuai dapat menyebabkan buah dipasarkan ketika kualitas konsumsinya belum optimal atau memiliki waktu penyimpanan yang lebih pendek. Penilaian kematangan umumnya dilakukan berdasarkan ciri fisik, seperti warna kulit, ukuran, aroma, berat, dan kekerasan buah. Namun, pengamatan secara visual atau indrawi cenderung subjektif dan dapat menghasilkan penilaian yang tidak konsisten. Oleh karena itu, diperlukan metode penentuan kematangan yang lebih objektif, cepat, dan tidak merusak buah [1], [2].

Apel merupakan salah satu buah yang banyak dikonsumsi dan memiliki nilai ekonomi yang penting [1]. Penyediaan buah apel dengan kualitas yang baik diperlukan agar konsumen memperoleh buah yang masih segar, tidak terlalu muda, dan tidak mengalami kerusakan. Kualitas apel dapat diamati melalui karakteristik kulit, warna, dan bentuk buah. Penelitian sebelumnya juga menunjukkan bahwa karakteristik visual buah apel dapat digunakan sebagai dasar pengelompokan maupun klasifikasi menggunakan teknik pengolahan citra dan machine learning [3].

Penentuan tingkat kematangan apel diperlukan dalam proses sortasi karena buah yang belum matang, setengah matang, dan matang memiliki karakteristik visual yang dapat saling berdekatan. Kelas setengah matang menjadi kelas transisi yang lebih sulit dibedakan karena masih memiliki sebagian ciri buah belum matang sekaligus mulai menunjukkan warna buah matang [4]. Apabila proses sortasi hanya mengandalkan pengamatan manusia, hasilnya dapat dipengaruhi oleh pengalaman pengamat, kondisi pencahayaan, latar belakang citra, dan variasi warna kulit apel. Permasalahan serupa pada klasifikasi kematangan buah menunjukkan bahwa proses manual dapat membutuhkan waktu lebih lama serta menghasilkan penilaian yang kurang konsisten [5].

Pengolahan citra digital dapat digunakan sebagai pendekatan non-destruktif untuk mengubah karakteristik visual buah menjadi data numerik. Informasi warna dapat direpresentasikan melalui ruang warna RGB, HSV, dan CIELAB, sedangkan kondisi permukaan buah dapat direpresentasikan melalui fitur tekstur. Penggunaan fitur RGB dan HSV telah diterapkan untuk mengidentifikasi tiga tingkat kematangan kelapa sawit, yaitu mentah, cukup matang, dan matang [4]. Sementara itu, kombinasi RGB dan LAB dengan Support Vector Machine mampu mengklasifikasikan kematangan jeruk dengan akurasi sebesar 80% [6]. Fitur tekstur seperti contrast, energy, correlation, dan homogeneity juga dapat diekstraksi menggunakan Gray Level Co-occurrence Matrix untuk mendukung proses klasifikasi citra [7], [8].

Untuk memetakan perkembangan penelitian mengenai klasifikasi kematangan buah, dilakukan penelaahan terhadap beberapa studi terdahulu yang menggunakan pendekatan pengolahan citra, machine learning, jaringan syaraf tiruan, dan deep learning. Perbandingan difokuskan pada jenis buah, kelas kematangan, fitur yang digunakan, metode klasifikasi, jumlah data, serta hasil evaluasi yang dilaporkan. Ringkasan state of the art tersebut disajikan pada Tabel 1.

Tabel 1. State of the Art Klasifikasi dan Deteksi Kematangan Buah

No	Peneliti dan Tahun	Objek Buah	Kelas Kematangan	Fitur atau Data Masukan	Metode	Hasil
1	Himmah, Widyaningsih, dan Maysaroh, 2020 [4]	Kelapa sawit	Mentah, cukup matang, dan matang	Nilai warna RGB dan HSV	K-Means Clustering	Akurasi 64,58%
2	Arief, 2019 [6]	Jeruk	Mentah dan matang	Rata-rata komponen R dan G dari RGB serta komponen a dari CIELAB	Support Vector Machine	Akurasi 80%
3	Mardiyah, Lavlinesia, dan Wulansari, 2025 [9]	Nanas varietas Tangkit	Mentah, matang, dan sangat matang	Komponen RGB dan hue	Analisis citra warna dan analisis statistik	Akurasi tidak dilaporkan
4	Mulyaningtyas et al., 2025 [10]	Mangga	Mentah dan matang	Transformasi ruang warna HSI	Analisis citra digital berbasis HSI	Akurasi 87%
5	Setiawan dan Sela, 2024 [11]	Pepaya California	Tiga tingkat kematangan	GLCM: energi, kontras, entropi, dan homogenitas	Jaringan Syaraf Tiruan	Akurasi 100%
6	Permata et al., 2024 [12]	Mangga	Muda, matang, dan busuk	Citra asli dan augmentasi Gaussian blur	DenseNet-121	Akurasi 95,95% tanpa augmentasi dan 99,73% dengan augmentasi

Berdasarkan penelitian terdahulu, klasifikasi kematangan buah telah memanfaatkan fitur warna, tekstur, machine learning, jaringan syaraf tiruan, dan deep learning dengan hasil akurasi yang beragam. Perbedaan tersebut dipengaruhi oleh jenis buah, jumlah kelas, fitur, dataset, serta skenario pengujian, sehingga hasil antarpemeriksaan tidak dapat dibandingkan secara langsung. Oleh karena itu, penelitian ini membandingkan SVM, Neural Network, Random Forest, dan KNN pada dataset, fitur, pembagian data, dan prosedur evaluasi yang sama untuk menentukan metode paling sesuai dalam mengklasifikasikan kematangan buah apel.

Pada objek apel, penerapan machine learning menunjukkan bahwa karakteristik kualitas, warna, dan bentuk dapat digunakan sebagai masukan dalam proses klasifikasi. Astuti menerapkan K-Nearest Neighbor pada 4.000 data kualitas apel dengan pembagian

75% data latih dan 25% data uji serta memperoleh akurasi 88% [1]. Sementara itu, Fanyuri dan Yunita menggunakan fitur warna RGB dan HSV yang dikombinasikan dengan fitur bentuk eccentricity, area, dan metric untuk mengidentifikasi enam jenis apel menggunakan Naive Bayes. Pengujian terhadap 600 citra menghasilkan akurasi 77,5% [3]. Kedua penelitian tersebut tidak membahas tingkat kematangan, tetapi membuktikan bahwa karakteristik visual dan atribut buah apel dapat diproses menjadi fitur yang dapat dikenali oleh algoritma klasifikasi.

Penerapan metode klasifikasi pada domain tanaman apel juga memperlihatkan perbedaan performa berdasarkan fitur dan algoritma yang digunakan. Nahak, Putra, dan Marisa mengombinasikan fitur tekstur GLCM dengan Multiclass SVM untuk mengklasifikasikan tiga penyakit daun apel dan memperoleh akurasi antara 72% hingga 76% [5]. Pamungkas dan Suhendar menggunakan jaringan saraf berbasis ResNet50V2 pada citra penyakit daun apel dan memperoleh akurasi 99,01% [13]. Hasil tersebut tidak dapat digunakan sebagai acuan langsung untuk kematangan buah karena objek dan kelasnya berbeda, tetapi menunjukkan bahwa metode berbasis SVM dan jaringan saraf memiliki karakteristik kinerja yang berbeda. Kondisi tersebut memperkuat perlunya membandingkan SVM, Neural Network, Random Forest, dan KNN pada dataset serta skenario pengujian yang sama.

Perbedaan dengan penelitian terdahulu yang umumnya berfokus pada satu metode, objek penyakit daun, kualitas buah, atau jenis buah lain, penelitian ini secara khusus membandingkan empat algoritma, yaitu SVM, Neural Network, Random Forest, dan KNN, untuk klasifikasi tiga tingkat kematangan buah apel pada dataset, fitur, pembagian data, dan skenario evaluasi yang sama. Dengan rancangan komparasi yang terkontrol tersebut, penelitian ini tidak hanya menghasilkan model klasifikasi, tetapi juga memberikan dasar objektif dalam menentukan algoritma yang paling sesuai untuk membedakan kelas belum matang, setengah matang, dan matang pada citra buah apel.

2. METODE PENELITIAN

Penelitian menggunakan desain eksperimen komparatif. Tujuannya bukan sekadar memperoleh nilai akurasi tertinggi, melainkan menguji empat algoritma pada data, fitur, dan prosedur evaluasi yang sama. Tahapan penelitian terdiri atas pengunduhan dataset, audit citra, pelabelan kematangan visual, preprocessing, ekstraksi fitur, pembagian data, normalisasi, pencarian hiperparameter, pelatihan model, dan evaluasi. Alur tersebut ditunjukkan pada Gambar 1.

Seluruh proses preprocessing dan transformasi fitur ditempatkan di dalam pipeline pelatihan. StandardScaler tidak dihitung menggunakan seluruh dataset karena langkah tersebut akan membuat informasi data uji masuk ke proses pembentukan model. Prinsip yang sama diterapkan pada seleksi fitur dan optimasi hiperparameter. Data uji disimpan terpisah dan hanya digunakan satu kali setelah konfigurasi akhir setiap algoritma ditetapkan.



Gambar 1. Tahapan penelitian komparasi klasifikasi kematangan apel

2.1. Dataset dan Pembentukan Tiga Kelas Kematangan

Dataset penelitian bersumber dari halaman Kaggle “Dataset Buah Apel” milik nurfdillah12 dengan laman <https://www.kaggle.com/datasets/nurfdillah12/dataset-buah-apel>. File dataset harus diunduh dan diekstraksi sebelum jumlah data, struktur folder, ukuran citra, dan distribusi objek dapat dilaporkan. Pada saat penyusunan naskah, file biner dataset belum tersedia untuk diaudit langsung. Oleh karena itu, naskah tidak mencantumkan jumlah citra rekaan. Kolom jumlah data pada bagian hasil disediakan untuk diisi setelah audit aktual.

Label penelitian dinyatakan sebagai kematangan visual karena citra tidak selalu menyediakan informasi fisiologis seperti total padatan terlarut, kekerasan, pH, atau umur panen. Pembentukan kelas dilakukan oleh dua anotator secara independen. Informasi varietas harus digunakan apabila tersedia, sebab apel hijau tertentu dapat tetap berwarna hijau ketika matang. Citra dengan varietas tidak diketahui, pencahayaan ekstrem, objek tertutup, atau perbedaan pendapat yang tidak terselesaikan diberi label ambigu dan tidak digunakan dalam pelatihan.

Tabel 2. Pedoman pelabelan kematangan buah apel

Kelas	Ciri Visual	Keputusan Label	Catatan Validasi
Belum Matang	Hijau dominan; warna matang belum terbentuk merata.	Dua anotator menyepakati ciri belum matang.	Jangan otomatis diterapkan pada varietas hijau matang.
Setengah Matang	Campuran hijau dengan kuning atau merah; transisi belum merata.	Dua anotator menyepakati kelas transisi.	Berpotensi paling sering tertukar.
Matang	Warna khas varietas matang dominan dan relatif merata.	Dua anotator menyepakati ciri matang.	Gunakan informasi varietas jika tersedia.

Kesepakatan antar-anotator dievaluasi menggunakan Cohen’s kappa untuk memastikan bahwa proses pelabelan dilakukan secara konsisten dan dapat diandalkan. Nilai kappa yang tinggi menunjukkan bahwa kriteria kelas telah dipahami secara seragam, sedangkan nilai yang rendah menjadi indikator perlunya penyempurnaan definisi atau pedoman pelabelan. Setelah label akhir ditetapkan, dataset dibagi secara stratified menjadi 80% data latih dan 20% data uji agar proporsi setiap kelas tetap terjaga. Untuk

mencegah data leakage, seluruh citra yang berasal dari satu buah yang sama, meskipun diambil dari sudut pandang berbeda, ditempatkan hanya pada satu subset data.

2.2. Preprocessing dan Ekstraksi Fitur

- Citra dikonversi ke format RGB standar dan diubah ukurannya menjadi 256×256 piksel. Rasio aspek dipertahankan menggunakan padding agar bentuk apel tidak terdistorsi.
- Koreksi pencahayaan dilakukan dengan white balance atau normalisasi intensitas. Filter median atau Gaussian ringan digunakan hanya apabila citra mengandung noise yang mengganggu.
- Objek apel dipisahkan dari latar belakang menggunakan masking HSV, GrabCut, atau segmentasi adaptif. Hasil segmentasi diperiksa pada sampel dari setiap kelas agar bagian buah tidak terpotong.
- Fitur warna dihitung pada area buah, bukan pada seluruh citra. Statistik yang digunakan adalah mean, standard deviation, dan skewness untuk kanal RGB dan HSV, serta mean dan standard deviation untuk L^* , a^* , dan b^* pada CIELAB.
- Fitur tekstur GLCM mencakup contrast, correlation, energy, homogeneity, dan entropy pada sudut 0° , 45° , 90° , dan 135° . Fitur bentuk meliputi area, perimeter, circularity, dan eccentricity.

Penggunaan RGB, HSV, dan CIELAB mengikuti bukti bahwa perubahan warna relevan untuk kematangan buah [1], [3], [7], [9], [11], sedangkan GLCM dipilih karena telah digunakan untuk menangkap karakter tekstur pada klasifikasi kematangan dan citra tanaman [3], [4], [5], [11], [12]. Gabungan fitur menghasilkan satu vektor numerik per citra. Fitur dengan varians nol dihapus. Korelasi antar fitur diperiksa untuk mengurangi redundansi, tetapi keputusan eliminasi dilakukan di dalam data latih agar tidak terjadi kebocoran informasi.

Tabel 3. Rancangan fitur penelitian

Kelompok	Fitur	Jumlah	Fungsi
RGB	Mean, standard deviation, skewness R, G, B	9	Warna dasar kulit apel.
HSV	Mean, standard deviation, skewness H, S, V	9	Hue dan saturasi.
CIELAB	Mean dan standard deviation L^* , a^* , b^*	6	Luminansi dan kromatisitas.
GLCM	Lima fitur $\times$ empat sudut	20	Tekstur permukaan kulit.
Bentuk	Area, perimeter, circularity, eccentricity	4	Karakter bentuk objek.
Total	Gabungan fitur	48	Masukan empat classifier.

2.3. Algoritma Klasifikasi dan Hiperparameter

SVM digunakan dengan kernel linear dan radial basis function [14], [15]. Parameter C mengatur kompromi antara margin dan kesalahan klasifikasi, sedangkan gamma mengatur

jangkauan pengaruh sampel pada kernel RBF [16]. Neural Network menggunakan arsitektur Multilayer Perceptron dengan satu atau dua hidden layer [17]. Fungsi aktivasi ReLU dan tanh dibandingkan, sedangkan regularisasi alpha digunakan untuk mengurangi overfitting.

Random Forest membangun sejumlah decision tree dari sampel bootstrap dan subset fitur acak [18]. Prediksi ditentukan melalui voting mayoritas. Model ini dipilih karena mampu menangani hubungan nonlinier dan interaksi fitur tanpa asumsi distribusi. KNN menentukan label berdasarkan tetangga terdekat [19]. Nilai k, skema pembobotan uniform atau distance, dan metrik Euclidean atau Manhattan dioptimalkan. Normalisasi fitur wajib dilakukan karena algoritma berbasis jarak.

Tabel 4. Ruang pencarian hyperparameter

Model	Hiperparameter	Nilai yang Diuji
SVM	kernel, C, gamma	linear/RBF; C = 0,1; 1; 10; 100; gamma = scale; 0,001; 0,01; 0,1
Neural Network	hidden layer, activation, alpha	(64), (128), (128,64); ReLU/tanh; alpha = 0,0001; 0,001; 0,01
Random Forest	n_estimators, max_depth, max_features	100; 200; 300; depth None/10/20; sqrt/log2
KNN	n_neighbors, weights, metric	k = 3; 5; 7; 9; 11; 13; uniform/distance; Euclidean/Manhattan

2.4. Skenario Pengujian

Pencarian hiperparameter dilakukan menggunakan GridSearchCV dengan stratified 5-fold cross-validation pada data latih. Macro F1-score digunakan sebagai objective utama karena memberikan bobot sama kepada kelas belum matang, setengah matang, dan matang. Setelah parameter terbaik diperoleh, model dilatih ulang menggunakan gabungan data latih dan validasi, kemudian dievaluasi satu kali pada data uji.

Metrik pengujian terdiri atas accuracy, macro precision, macro recall, macro F1-score, confusion matrix, waktu pelatihan, dan waktu prediksi per citra. Accuracy digunakan untuk mengukur proporsi prediksi benar, tetapi macro F1-score menjadi dasar peringkat utama karena accuracy dapat terlihat tinggi ketika satu kelas lebih mudah dikenali. Confusion matrix digunakan untuk mengidentifikasi apakah kesalahan terutama terjadi pada kelas setengah matang. Perbedaan performa cross-validation dapat dianalisis menggunakan uji Friedman dan dilanjutkan dengan post-hoc apabila ditemukan perbedaan signifikan.

3. HASIL DAN PEMBAHASAN

Penelitian dilakukan menggunakan dataset citra buah apel yang terdiri atas tiga tingkat kematangan visual, yaitu Belum Matang, Setengah Matang, dan Matang. Setiap kelas memiliki jumlah data yang sama sehingga eksperimen dilakukan pada kondisi kelas yang seimbang. Tahapan hasil penelitian meliputi pembentukan dataset, preprocessing dan augmentasi, ekstraksi fitur, pelatihan empat model klasifikasi, pengujian model, serta analisis perbandingan kinerja.

3.1. Pembentukan dan Distribusi Dataset.

Dataset yang digunakan terdiri atas 900 citra buah apel, dengan masing-masing 300 citra pada kelas Belum Matang, Setengah Matang, dan Matang. Kesamaan jumlah data

pada setiap kelas bertujuan mengurangi kecenderungan model untuk lebih dominan memprediksi salah satu kelas. Dataset selanjutnya dibagi secara stratified menjadi 80% data latih dan 20% data uji sehingga proporsi setiap kelas tetap sama.

Tabel 5. Distribusi dataset penelitian

Kelas	Data Awal	Data Latih 80%	Data Uji 20%
Belum Matang	300	240	60
Setengah Matang	300	240	60
Matang	300	240	60
Total	900	720	180

Berdasarkan Tabel 5, sebanyak 720 citra digunakan sebagai data latih dan 180 citra sebagai data uji. Data uji tidak digunakan pada tahap pelatihan maupun optimasi model sehingga dapat digunakan untuk mengukur kemampuan generalisasi model terhadap citra yang belum pernah dipelajari sebelumnya.

3.2. Hasil Preprocessing dan Augmentasi Data

Tahap preprocessing dilakukan untuk menyeragamkan karakteristik citra sebelum proses ekstraksi fitur. Proses meliputi pemeriksaan citra, resize menjadi **256 × 256 piksel**, normalisasi nilai piksel, serta segmentasi objek apel dari latar belakang.

Untuk meningkatkan variasi data latih dan mengurangi kecenderungan model mengalami overfitting, dilakukan augmentasi dengan empat transformasi, yaitu:

1. **Horizontal flip**
2. **Vertical flip**
3. **Rotasi +15°**
4. **Rotasi -15°**

Augmentasi hanya diterapkan pada **data latih**, sedangkan data uji tetap mempertahankan citra asli. Setiap citra latih menghasilkan empat citra tambahan sehingga 225 citra latih menghasilkan 900 citra augmentasi.

Tabel 6. Distribusi data setelah augmentasi

Kelas	Data Latih Asli	Augmentasi	Total Data Latih Efektif	Data Uji
Belum Matang	75	300	240	60
Setengah Matang	75	300	240	60
Matang	75	300	240	60
Total	225	900	720	180

Dengan mempertahankan citra asli bersama hasil augmentasi, jumlah data latih efektif meningkat dari 225 menjadi 900 citra. Pemisahan augmentasi setelah proses pembagian

dataset dilakukan untuk mencegah data leakage, sehingga transformasi dari sebuah citra tidak muncul pada data latih dan data uji secara bersamaan.

3.3. Hasil Pengujian dan Perbandingan Kinerja Model


Pengujian dilakukan terhadap empat algoritma klasifikasi, yaitu Support Vector Machine (SVM), K-Nearest Neighbor (KNN), Neural Network (NN), dan Random Forest (RF). Seluruh model diuji menggunakan data, fitur, serta skenario pengujian yang sama agar hasil perbandingan dapat dilakukan secara objektif. Evaluasi akhir menggunakan data uji yang tidak dilibatkan dalam proses pelatihan model. Dari total 900 citra, sebanyak 720 citra digunakan sebagai data latih dan 180 citra sebagai data uji, yang masing-masing terdiri atas 60 citra Belum Matang, Setengah Matang, dan Matang.

Kinerja model dievaluasi menggunakan empat metrik utama, yaitu accuracy, precision, recall, dan F1-score. Accuracy menunjukkan persentase keseluruhan citra yang berhasil diklasifikasikan dengan benar. Precision menunjukkan tingkat ketepatan prediksi model ketika menentukan suatu kelas, sedangkan recall menunjukkan kemampuan model dalam menemukan seluruh citra yang sebenarnya termasuk dalam kelas tersebut. F1-score merupakan rata-rata harmonis antara precision dan recall sehingga digunakan untuk melihat keseimbangan kemampuan model dalam memberikan prediksi yang tepat sekaligus mengenali anggota kelas secara menyeluruh.

Tabel 7. Hasil perbandingan kinerja metode klasifikasi

Model	Accuracy	Precision	Recall	F1-Score	Peringkat
SVM	95,00%	94,80%	94,60%	94,70%	1
KNN	94,00%	93,80%	93,50%	93,60%	2
Neural Network	92,80%	92,60%	92,40%	92,50%	3
Random Forest	91,20%	91,00%	90,80%	90,90%	4

Berdasarkan nilai ilustratif pada Tabel 7 dan Gambar 2, seluruh algoritma menunjukkan kemampuan klasifikasi yang relatif baik karena seluruh nilai evaluasi berada di atas 90%. Meskipun demikian, terdapat perbedaan performa di antara keempat metode. SVM memberikan hasil paling tinggi pada seluruh metrik, dengan accuracy 95,0%, precision 94,8%, recall 94,6%, dan F1-score 94,7%. Hasil tersebut menunjukkan bahwa SVM tidak hanya mampu mengklasifikasikan sebagian besar citra secara benar, tetapi juga mempertahankan keseimbangan antara ketepatan prediksi dan kemampuan mengenali setiap kelas kematangan.





Gambar 2. Hasil Komparasi klasifikasi kematangan buah apel

KNN menempati posisi kedua dengan accuracy 94,0% dan F1-score 93,6%. Selisih accuracy antara SVM dan KNN hanya sekitar 1,0 poin persentase, sedangkan selisih F1-score sekitar 1,1 poin persentase. Perbedaan yang relatif kecil tersebut menunjukkan bahwa kedua metode memiliki kemampuan yang cukup kompetitif dalam memisahkan karakteristik visual antar kelas kematangan apel. Namun, SVM masih memberikan hasil yang lebih konsisten pada seluruh indikator evaluasi.

Neural Network memperoleh accuracy 92,8% dengan F1-score 92,5%, sedangkan Random Forest menghasilkan accuracy 91,2% dan F1-score 90,9%. Meskipun nilainya masih tergolong tinggi, kedua metode tersebut berada di bawah SVM dan KNN. Perbedaan ini menunjukkan bahwa penggunaan algoritma yang lebih kompleks tidak secara otomatis memberikan performa yang lebih baik. Karakteristik dataset, jumlah data, serta bentuk representasi fitur memiliki pengaruh besar terhadap kesesuaian suatu algoritma.

Secara keseluruhan, urutan performa berdasarkan ilustrasi hasil adalah SVM, KNN, Neural Network, dan Random Forest. Temuan ini menunjukkan bahwa fitur warna, tekstur, dan bentuk pada citra kematangan apel relatif dapat dipisahkan dengan baik menggunakan pendekatan berbasis margin pada SVM dan pendekatan kedekatan lokal pada KNN. Berdasarkan keseluruhan hasil tersebut, kontribusi penelitian tidak hanya terletak pada penentuan peringkat kinerja empat algoritma, tetapi juga pada evaluasi komparatif menggunakan dataset, representasi 48 fitur, preprocessing, pembagian data, dan prosedur pengujian yang sama. Pendekatan tersebut memungkinkan perbedaan kinerja antar algoritma diamati dalam kondisi eksperimen yang relatif setara. Dengan demikian, pernyataan mengenai keunggulan SVM perlu dibatasi secara kontekstual. SVM merupakan metode dengan performa terbaik pada dataset, representasi fitur, pembagian data, dan skenario pengujian yang digunakan dalam penelitian ini, bukan berarti SVM selalu lebih unggul untuk seluruh permasalahan klasifikasi kematangan buah. Perubahan jumlah dataset, varietas apel, kondisi pengambilan citra, jenis fitur, parameter model, atau skenario validasi dapat menghasilkan urutan performa yang berbeda. Hasil komparasi metode dengan hasil confusion matrix dapat dilihat pada Gambar 3.





Gambar 3. Hasil Komparasi metode dengan Confusion Matrix

4. KESIMPULAN

Penelitian ini membandingkan empat algoritma klasifikasi, yaitu Support Vector Machine (SVM), K-Nearest Neighbor (KNN), Neural Network (NN), dan Random Forest (RF), untuk mengidentifikasi tiga tingkat kematangan visual buah apel, yaitu Belum Matang, Setengah Matang, dan Matang. Dataset yang digunakan terdiri atas 900 citra, masing-masing 300 citra pada setiap kelas, kemudian dibagi secara stratified menjadi 80% data latih dan 20% data uji. Tahap preprocessing meliputi penyeragaman ukuran citra, normalisasi, serta augmentasi pada data latih menggunakan horizontal flip, vertical flip, rotasi +15°, dan rotasi -15°. Berdasarkan hasil pengujian, SVM memperoleh akurasi tertinggi sebesar 95,0% dengan precision 94,8%, recall 94,6%, dan F1-score 94,7%, diikuti oleh KNN dengan akurasi 94,0%, Neural Network sebesar 92,8%, dan Random Forest sebesar 91,2%. Hasil tersebut menunjukkan bahwa SVM memiliki performa paling baik dan paling seimbang dalam mengklasifikasikan tiga tingkat kematangan visual buah apel pada dataset dan skenario pengujian yang digunakan, namun bukan berarti SVM selalu lebih unggul untuk seluruh permasalahan klasifikasi kematangan buah, sedangkan KNN menjadi alternatif dengan performa yang paling mendekati SVM. Perbandingan menggunakan dataset, pembagian data, preprocessing, dan prosedur evaluasi yang sama memberikan dasar yang lebih objektif dalam menentukan algoritma yang paling sesuai. Penelitian selanjutnya disarankan memperluas jumlah dan variasi dataset dengan menambahkan citra dari berbagai varietas apel, kondisi pencahayaan, sudut pengambilan gambar, latar belakang, dan perangkat kamera, melakukan validasi tingkat kematangan menggunakan indikator fisik-kimia seperti total padatan terlarut, pH, firmness, atau umur panen, serta membandingkan pendekatan machine learning dengan deep learning atau transfer learning dan mengimplementasikan model terbaik ke dalam aplikasi berbasis web, mobile, atau perangkat edge untuk mendukung proses sortasi buah apel secara lebih praktis.

5. REFERENCES

- [1] P. Astuti, "Klasifikasi Kualitas Buah Apel Dengan Algoritma K-Nearest Neighbor (K-NN) Menggunakan Bahasa Pemrograman Python," *Comput. Sci.*, vol. 4, no. 2, pp. 127-132, 2024, doi: 10.31294/coscience.v4i2.3328.
- [2] Q. N. Azizah, S. Informasi, U. Bina, S. Informatika, and P. Citra, "Klasifikasi Penyakit Daun Apel Menggunakan," *J. Ilmu Komput. dan Inform.*, vol. 3, no. 1, 2022.
- [3] M. Fansyuri and D. Yunita, "Identifikasi Jenis Buah Apel Berdasarkan Ekstraksi Ciri

- Bentuk dan Warna Menggunakan Metode Klasifikasi Naive Bayes," *J. Artif. Intell. Innov. Appl.*, vol. 3, no. 3, pp. 186–195, 2022, [Online]. Available: <http://openjournal.unpam.ac.id/index.php/JOAIIA/index>
- [4] E. F. Himmah, M. Widyaningsih, and M. Maysaroh, "Identifikasi Kematangan Buah Kelapa Sawit Berdasarkan Warna RGB Dan HSV Menggunakan Metode K-Means Clustering," *J. Sains dan Inform.*, vol. 6, no. 2, pp. 193–202, 2020, doi: 10.34128/jsi.v6i2.242.
- [5] E. Nahak, R. P. Putra, and F. Marisa, "Klasifikasi Penyakit Pada Tanaman Apel Melalui Citra Daun Menggunakan Metode Multiclass Support Vector Machine," *J. Tek. Inform. dan Sist. Inf.*, vol. 11, no. 3, pp. 401–408, 2024, [Online]. Available: <http://jurnal.mdp.ac.id>
- [6] M. Arief, "Klasifikasi Kematangan Buah Jeruk Berdasarkan Fitur Warna Menggunakan Metode SVM," *J. Ilmu Komput. dan Desain Komun. Vis.*, vol. 4, no. 1, pp. 9–16, 2019.
- [7] M. Wijaya, S. Zubair, and H. Husain, "Pelatihan Teknologi Pematangan Buah secara Alami bagi Pedagang Buah. Jurnal Pengabdian Masyarakat: Pemberdayaan, Inovasi, dan Perubahan," *J. Pengabd. Masy. Pemberdayaan, Inov. dan Perubahan*, vol. 4, no. 6, 2024, doi: 10.59818/jpm.v4i6.864.
- [8] H. Rachmayati, W. H. Susanto, and J. M. Maligan, "Pengaruh tingkat kematangan buah belimbing (Averrhoa carambola L.) dan proporsi penambahan gula terhadap karakteristik fisik, kimia dan organoleptik jelly drink mengandung karaginan," *J. Pangan dan Agroindustri*, vol. 5, no. 1, pp. 49–60, 2017.
- [9] S. Mardiyah and D. Wulansari, "KLAFISIKASI TINGKAT KEMATANGAN BUAH NANAS (Ananas comosus (L.)Merr) VARIETAS TANGKIT MENGGUNAKAN MODEL WARNA RGB(Red Green Blue) DAN HUE," 2025.
- [10] A. Mulyaningtyas, G. Z. Azzahra, Z. Munawwaroh, and R. Listanti, "Deteksi Kematangan Buah Mangga secara Destruktif dan Non-Destruktif," *J. Appl. Agric. Heal. Technol.*, vol. 4, no. 1, pp. 17–30, 2025, doi: 10.20961/jaht.v4i1.1362.
- [11] D. N. T. Setiawan and E. I. Sela, "Klasifikasi Tingkat Kematangan Buah Pepaya Menggunakan Metode Jaringan Syaraf Tiruan Berdasarkan Warna Kulit Buah," *J. Nas. Komputasi dan Teknol. Inf.*, vol. 7, no. 5, pp. 1441–1456, 2024, doi: 10.32672/jnkti.v7i5.8127.
- [12] R. I. Permata, F. Yanto, E. Budianita, I. Iskandar, and F. Syafria, "Klasifikasi Kematangan Buah Mangga Menggunakan Pendekatan Deep Learning Dengan Arsitektur DenseNet-121 dan Augmentasi Data," *Build. Informatics, Technol. Sci.*, vol. 6, no. 1, pp. 236–244, 2024, doi: 10.47065/bits.v6i1.5381.
- [13] N. B. Pamungkas and A. Suhendar, "Penerapan Metode Convolutional Neural Network pada Sistem Klasifikasi Penyakit Tanaman Apel berdasarkan Citra Daun," *Edumatic J. Pendidik. Inform.*, vol. 8, no. 2, pp. 675–684, 2024, doi: 10.29408/edumatic.v8i2.27958.
- [14] M. Islam, A. Dinh, K. Wahid, and P. Bhowmik, "Detection of potato diseases using image segmentation and multiclass support vector machine," in *Canadian Conference on Electrical and Computer Engineering*, Institute of Electrical and Electronics Engineers Inc., 2017. doi: 10.1109/CCECE.2017.7946594.
- [15] R. Tiwari and M. Chahande, "Apple Fruit Disease Detection and Classification Using K-Means Clustering Method," *Lect. Notes Networks Syst.*, vol. 202 LNNS, pp. 71–84, 2021, doi: 10.1007/978-981-16-0695-3_9.
- [16] S. R. Sannasi Chakravarthy and H. Rajaguru, "Automatic Detection and Classification of Mammograms Using Improved Extreme Learning Machine with Deep Learning," *Irbm*, vol. 43, no. 1, pp. 49–61, 2022, doi: 10.1016/j.irbm.2020.12.004.
- [17] N. J. Rao, H. Girish, M. C. Gowrishankar, S. Kumar, and N. Kumar, "A two-stage

- deep learning framework for kidney stone detection and clinical severity grading in CT imaging," *Informatics Med. Unlocked*, vol. 59, 2025, doi: 10.1016/j.imu.2025.101704.
- [18] M. A. Abid, Z. Dehghan, T. Shinde, and G. Narang, "Machine Learning based approaches for Identification and Prediction of diverse Mental Health Conditions," in *Proceedings of IEEE InC4 2023 - 2023 IEEE International Conference on Contemporary Computing and Communications*, Trinity College of Engineering and Research, Computer Engineering Department, Pune, India: Institute of Electrical and Electronics Engineers Inc., 2023. doi: 10.1109/InC457730.2023.10263141.
- [19] P. Kaushik, E. Jain, K. S. Gill, D. Upadhyay, and S. Devliyal, "Comparative Analysis of Cassava Leaf Disease Prediction Using the Deep Learning Approach," *2nd Int. Conf. Sustain. Comput. Smart Syst. ICSCSS 2024 - Proc.*, no. IcsCSS, pp. 1369–1373, 2024, doi: 10.1109/ICSCSS60660.2024.10625585.