

BAB II

TINJAUAN PUSTAKA

2.1 Buah Alpukat

Alpukat (*Persea americana* Mill.) merupakan tanaman buah tahunan yang berasal dari Amerika Tengah dan Meksiko, dan saat ini telah dibudidayakan secara luas di berbagai wilayah beriklim tropis dan subtropis, termasuk Indonesia. Tanaman ini termasuk dalam famili Lauraceae dan memiliki nilai ekonomi yang tinggi karena kandungan nutrisinya yang melimpah, seperti lemak tak jenuh tunggal, vitamin E, vitamin K, folat, serta berbagai mineral penting yang bermanfaat bagi kesehatan (AFZAL et al., 2022).

Di Indonesia, alpukat dibudidayakan dalam berbagai varietas, baik varietas introduksi maupun varietas lokal, yang banyak dijumpai di pasar tradisional maupun modern. Setiap varietas memiliki karakteristik morfologi serta perubahan warna kulit yang berbeda selama proses pematangan. Pada beberapa varietas, warna kulit berubah dari hijau menjadi hijau tua atau kehitaman ketika matang, sedangkan pada varietas lainnya perubahan warna relatif tidak terlalu mencolok. Perbedaan karakteristik tersebut menunjukkan bahwa warna kulit alpukat dapat bervariasi, sehingga identifikasi tingkat kematangan tidak selalu dapat dilakukan secara konsisten hanya berdasarkan pengamatan visual (Pinto et al., 2019).

Alpukat termasuk ke dalam kelompok buah *climacteric*, yaitu buah yang masih mengalami peningkatan laju respirasi dan produksi etilen setelah dipanen. Selama proses pematangan terjadi berbagai perubahan fisiologis dan biokimia, seperti degradasi klorofil pada kulit buah, perubahan komposisi pigmen, pelunakan

tekstur akibat degradasi dinding sel, serta perubahan kandungan gula dan asam organik. Perubahan tersebut memengaruhi karakteristik visual kulit buah, terutama pada aspek warna, kecerahan, dan tingkat kejenuhan warna yang dapat diamati secara langsung maupun dianalisis menggunakan teknik pengolahan citra digital (AFZAL et al., 2022).

Dalam penelitian ini, klasifikasi dilakukan berdasarkan tingkat kematangan buah, yaitu mentah, setengah matang, dan matang, menggunakan karakteristik warna yang diekstraksi dari citra digital. Variasi perubahan warna kulit selama proses pematangan menjadi salah satu alasan penggunaan ruang warna HSV (Hue, Saturation, Value), karena mampu merepresentasikan informasi warna secara lebih stabil dibandingkan ruang warna RGB, terutama ketika terdapat variasi intensitas pencahayaan.

2.2 Pengolahan Citra Digital

Pengolahan citra digital (digital image processing) adalah bidang ilmu yang mempelajari teknik-teknik untuk memanipulasi dan menganalisis citra digital menggunakan komputer. Citra digital merupakan representasi visual objek dalam bentuk matriks numerik yang terdiri dari elemen-elemen diskrit yang disebut piksel (picture element). Setiap piksel menyimpan informasi intensitas atau warna pada posisi tertentu dalam citra (Minaee et al., 2022).

Tahapan umum dalam pengolahan citra digital meliputi: (1) Akuisisi citra: proses menangkap citra menggunakan perangkat seperti kamera digital atau scanner, (2) Preprocessing: perbaikan kualitas citra seperti noise reduction, contrast

enhancement, dan koreksi pencahayaan, (3) Segmentasi: pemisahan objek dari background atau pemisahan region of interest, (4) Ekstraksi fitur: mengidentifikasi dan mengukur atribut-atribut penting dari citra, dan (5) Klasifikasi/Interpretasi: pengenalan pola atau pengambilan keputusan berdasarkan fitur yang diekstraksi.

Dalam konteks klasifikasi buah, pengolahan citra digital memungkinkan ekstraksi informasi objektif dan kuantitatif tentang karakteristik buah seperti warna, tekstur, bentuk, dan ukuran. Pendekatan ini mengatasi keterbatasan metode manual yang bersifat subjektif dan tidak konsisten. Dengan menggunakan algoritma computer vision, sistem dapat melakukan analisis citra secara otomatis, cepat, dan dengan tingkat akurasi yang tinggi.

2.3 Ruang Warna HSV

Ruang warna HSV (Hue, Saturation, Value) adalah model warna yang merepresentasikan warna berdasarkan tiga komponen: Hue (rona warna), Saturation (saturasi/kemurnian warna), dan Value (nilai kecerahan). Model HSV lebih intuitif dan sesuai dengan persepsi manusia terhadap warna dibandingkan model RGB (Red, Green, Blue) yang berbasis pencampuran warna primer (Bhargava & Bansal, 2021).

Komponen-komponen HSV dijelaskan sebagai berikut:

1. Hue (H): Merepresentasikan jenis warna yang dinyatakan dalam derajat pada color wheel (0° - 360°). Nilai 0° merepresentasikan warna merah, 120° hijau, dan 240° biru. Untuk klasifikasi alpukat, perubahan Hue dari sekitar

90°-120° (hijau kekuningan) menjadi 30°-60° (coklat) mengindikasikan proses pematangan.

2. Saturation (S): Menunjukkan kemurnian atau intensitas warna dalam persentase (0-100%). Nilai 0% berarti warna abu-abu (tanpa warna), sedangkan 100% berarti warna murni tanpa campuran putih atau abu-abu. Pada alpukat matang, saturasi cenderung meningkat karena warna menjadi lebih pekat.
3. Value (V): Mencerminkan kecerahan warna dalam persentase (0-100%). Nilai 0% berarti hitam (gelap total), sedangkan 100% berarti kecerahan maksimum. Alpukat mengalami penurunan value seiring pematangan karena kulit menjadi lebih gelap.

Keunggulan utama ruang warna HSV untuk klasifikasi buah adalah robustness terhadap variasi pencahayaan. Perubahan intensitas cahaya terutama mempengaruhi komponen Value, sementara Hue dan Saturation relatif lebih stabil. Hal ini berbeda dengan RGB dimana perubahan pencahayaan mempengaruhi ketiga channel secara proporsional, sehingga lebih sensitif terhadap kondisi iluminasi (Bhargava & Bansal, 2021).

2.4 Ekstraksi Fitur

Ekstraksi fitur adalah proses mengidentifikasi dan mengukur karakteristik atau atribut yang relevan dari data citra yang dapat digunakan untuk membedakan objek atau kategori yang berbeda. Dalam konteks pengolahan citra, fitur dapat berupa: fitur warna (color features), fitur tekstur (texture features), fitur bentuk

(shape features), atau kombinasi dari ketiganya. Pemilihan jenis fitur yang tepat sangat menentukan keberhasilan sistem klasifikasi (Bhargava & Bansal, 2021).

Ekstraksi fitur warna bertujuan untuk menangkap informasi distribusi warna dalam citra. Pendekatan yang umum digunakan meliputi color histogram, color moments, dan color coherence vector. Color moments adalah metode yang menggunakan statistik matematis untuk mendeskripsikan distribusi warna, meliputi:

1. Mean (μ): Rata-rata nilai piksel yang menunjukkan warna dominan.
2. Standard Deviation (σ): Simpangan baku yang mengukur sebaran distribusi warna.
3. Skewness: Mengukur asimetri distribusi warna.
4. Kurtosis: Mengukur ketajaman atau keruncingan distribusi warna.
5. Minimum dan Maximum: Nilai ekstrem dalam distribusi warna.
6. Median: Nilai tengah distribusi.
7. Variance: Kuadrat dari standard deviation.
8. Interquartile Range (IQR): Rentang antara kuartil pertama dan ketiga.

Dalam penelitian ini, ekstraksi fitur dilakukan pada setiap channel HSV (H, S, dan V) dengan menghitung 9 parameter statistik untuk masing-masing channel, menghasilkan total 27 fitur. Pendekatan multi-fitur statistik ini terbukti efektif dalam menangkap karakteristik distribusi warna secara komprehensif dan meningkatkan discriminative power untuk klasifikasi.

2.5 Klasifikasi

Klasifikasi adalah proses pengelompokan data ke dalam kategori atau kelas yang telah ditentukan sebelumnya berdasarkan karakteristik atau fitur yang dimiliki. Dalam machine learning, klasifikasi termasuk dalam kategori supervised learning, dimana model dilatih menggunakan dataset berlabel untuk mempelajari pola yang membedakan antar kelas. Model yang telah terlatih kemudian dapat digunakan untuk memprediksi kelas dari data baru yang belum pernah dilihat sebelumnya (Kotsiantis, 2007).

Algoritma klasifikasi yang umum digunakan dalam machine learning meliputi:

1. Decision Tree: Membangun struktur pohon keputusan berdasarkan pemilihan fitur yang optimal.
2. Naive Bayes: Menggunakan teori probabilitas Bayesian dengan asumsi independensi antar fitur.
3. Support Vector Machine (SVM): Mencari hyperplane optimal yang memaksimalkan margin pemisah antar kelas.
4. K-Nearest Neighbor (KNN): Mengklasifikasikan berdasarkan mayoritas kelas dari k tetangga terdekat.
5. Random Forest: Ensemble dari multiple decision trees.
6. Neural Networks: Menggunakan arsitektur jaringan saraf tiruan yang terinspirasi dari otak manusia.

Pemilihan algoritma klasifikasi bergantung pada berbagai faktor termasuk: karakteristik dataset (ukuran, dimensi, distribusi), kompleksitas komputasi yang

dapat diterima, interpretabilitas hasil, dan performa yang diharapkan. Untuk aplikasi klasifikasi buah dengan dataset berukuran sedang dan kebutuhan implementasi yang efisien, K-Nearest Neighbor menjadi pilihan yang sesuai.

2.6 K-Nearest Neighbor (KNN)

K-Nearest Neighbor (KNN) adalah algoritma supervised learning yang sederhana namun powerful untuk klasifikasi dan regresi. Algoritma ini termasuk dalam kategori instance-based learning atau lazy learning, dimana tidak ada fase training eksplisit untuk membangun model. Sebagai gantinya, seluruh training dataset disimpan dalam memori, dan klasifikasi dilakukan dengan membandingkan data baru dengan seluruh data training (Kotsiantis, 2007).

Prinsip dasar KNN adalah "similarity", yaitu asumsi bahwa data dengan karakteristik yang mirip cenderung berada dalam kelas yang sama. Untuk mengklasifikasikan data baru, KNN melakukan langkah-langkah berikut:

1. Menghitung jarak antara data uji dengan seluruh data training menggunakan metrik jarak tertentu (biasanya Euclidean distance).
2. Mengurutkan jarak dari yang terkecil hingga terbesar.
3. Memilih k data training dengan jarak terkecil sebagai "tetangga terdekat".
4. Menentukan kelas mayoritas dari k tetangga tersebut.
5. Mengassign kelas mayoritas sebagai prediksi untuk data uji.

Metrik jarak yang paling umum digunakan dalam KNN adalah Euclidean distance, yang dihitung dengan formula:

$$d(x, y) = \sqrt{\sum (x_i - y_i)^2}$$

dimana x dan y adalah dua vektor fitur, dan i adalah indeks fitur dari 1 hingga n (jumlah fitur).

Parameter k (jumlah tetangga) adalah parameter krusial yang sangat mempengaruhi performa KNN:

1. k terlalu kecil (misalnya $k=1$): Model terlalu sensitif terhadap noise dan outliers, mengakibatkan overfitting.
2. k terlalu besar: Decision boundary menjadi terlalu smooth dan model kehilangan detail, mengakibatkan underfitting.
3. k optimal: Memberikan keseimbangan antara bias dan variance (bias-variance tradeoff).

Keunggulan KNN meliputi: (1) Sederhana dan mudah diimplementasikan, (2) Tidak memerlukan asumsi tentang distribusi data, (3) Efektif untuk dataset dengan decision boundary non-linear, (4) Dapat dengan mudah beradaptasi terhadap data baru tanpa retraining. Namun, KNN juga memiliki keterbatasan: (1) Waktu prediksi yang lambat untuk dataset besar karena harus menghitung jarak ke semua data training, (2) Sensitif terhadap fitur yang tidak relevan dan skala fitur, (3) Membutuhkan memori besar untuk menyimpan seluruh training data (Kotsiantis, 2007).

2.7 Evaluasi Performa Klasifikasi

Evaluasi performa adalah tahap penting untuk mengukur seberapa baik model klasifikasi dalam memprediksi data baru. Berbagai metrik evaluasi

digunakan untuk mengukur aspek yang berbeda dari performa model. Metrik-metrik utama yang umum digunakan dalam klasifikasi meliputi:

1. Accuracy (Akurasi): Proporsi prediksi yang benar terhadap total prediksi. Dihitung dengan formula: $\text{Accuracy} = (\text{TP} + \text{TN}) / (\text{TP} + \text{TN} + \text{FP} + \text{FN})$, dimana TP = True Positive, TN = True Negative, FP = False Positive, FN = False Negative. Akurasi memberikan gambaran keseluruhan performa model.
2. Precision (Presisi): Proporsi prediksi positif yang benar terhadap seluruh prediksi positif. Formula: $\text{Precision} = \text{TP} / (\text{TP} + \text{FP})$. Precision mengukur reliabilitas ketika model memprediksi kelas positif.
3. Recall/Sensitivity (Sensitivitas): Proporsi data positif aktual yang berhasil teridentifikasi. Formula: $\text{Recall} = \text{TP} / (\text{TP} + \text{FN})$. Recall mengukur kemampuan model mendeteksi seluruh instance dari kelas tertentu.
4. F1-Score: Harmonic mean dari precision dan recall. Formula: $\text{F1} = 2 \times (\text{Precision} \times \text{Recall}) / (\text{Precision} + \text{Recall})$. F1-score memberikan keseimbangan antara precision dan recall, berguna ketika distribusi kelas tidak seimbang.

Confusion Matrix adalah tabel yang memvisualisasikan performa klasifikasi dengan menampilkan prediksi versus label aktual. Untuk klasifikasi multi-class (lebih dari 2 kelas), confusion matrix berukuran $n \times n$ dimana n adalah jumlah kelas. Baris mewakili kelas aktual sedangkan kolom mewakili kelas prediksi. Diagonal utama menunjukkan prediksi yang benar, sedangkan elemen off-diagonal menunjukkan kesalahan klasifikasi.

Cross-validation adalah teknik untuk mengevaluasi robustness model dengan membagi dataset menjadi beberapa subset (folds). Pada k-fold cross-validation, dataset dibagi menjadi k bagian, kemudian dilakukan k iterasi training dan testing dimana setiap iterasi menggunakan satu fold sebagai data testing dan sisanya sebagai data training. Rata-rata performa dari k iterasi memberikan estimasi yang lebih reliable dibandingkan single train-test split.