

Pemilihan Algoritma *Machine Learning* untuk Perangkat dengan Komputasi Terbatas pada Deteksi Kematangan Buah Melon Berjala

Selection of Machine Learning Algorithms for Limited Computing Device in Netted Melon Ripeness Detection

RIZQI ALIFAHASNI ZAKIAH¹, SRI WAHJUNI^{1*}, WILLY BAYUARDI SUWARNO²

Abstrak

Karakteristik yang diinginkan dari buah melon oleh konsumen meliputi rasa manis, ukuran buah sedang hingga besar, daging tebal dengan warna menarik dan tekstur renyah, serta masa simpan yang relatif lama. Memprediksi waktu panen menjadi hal yang penting terkait masa simpan buah dengan harapan buah melon dapat mencapai konsumen dalam keadaan dan kualitas terbaik, serta memberikan pengalaman yang memuaskan bagi konsumen. Saat ini, ketersediaan tenaga kerja pemanen dengan kemampuan yang mumpuni dalam menentukan buah melon yang akan dipanen menjadi salah satu kendala. Penggunaan robot pertanian dalam pemanenan buah melon merupakan salah satu solusi yang efektif dalam mengatasi permasalahan tersebut. Robot pertanian ini membutuhkan sistem yang mampu memprediksi stadia kematangan buah melon untuk dipanen. Penelitian ini fokus pada analisis perbandingan kinerja antara dua algoritma *machine learning* yaitu *Support Vector Machine* (SVM) dan *Random Forest* (RF), dengan tujuan menentukan pilihan optimal saat menerapkannya pada perangkat komputasi terbatas. SVM dan RF memiliki nilai akurasi tinggi, masing-masing 82% dan 73%. Keduanya juga memiliki waktu komputasi yang cepat, dengan rata-rata waktu inferensi masing-masing 2.14 detik dan 2.15 detik. Rata-rata penggunaan CPU pada algoritma SVM lebih tinggi dibandingkan dengan algoritma RF yaitu 17.80% sedangkan RF 15.48%. Meskipun SVM memiliki *precision*, *recall*, dan *f-score* yang sedikit lebih tinggi dibandingkan dengan RF, namun setelah dilakukan *independent 2-samples t-test* terhadap *inference time* dan penggunaan CPU, didapatkan hasil bahwa tidak ada perbedaan nyata antara SVM dan RF. Keduanya sama-sama memiliki kinerja yang baik dan masuk ke dalam kategori *good classification*. Meninjau hal tersebut, algoritma RF menjadi algoritma yang disarankan karena memiliki tingkat akurasi yang baik, waktu komputasi cepat, dan penggunaan rata-rata sumberdaya CPU lebih rendah

Kata Kunci: buah melon, perangkat komputasi terbatas, pembelajaran mesin, *random forest*, *support vector machine*

Abstract

The desired characteristics of melon fruit by consumers include sweetness, medium to large fruit size, thick flesh with appealing color and crisp texture, and relatively long shelf life. Predicting the harvest time of the fruit is essential in achieving the best harvest results. evolving technologies such as agricultural robots can be utilized as effective solutions and means. The utilization of automated robots in melon harvesting serves as a relevant example of implementation. These agricultural robots require a system capable of predicting the ripeness of melons for harvest. The study focuses on analyzing the performance comparison between two machine learning algorithms, Support Vector Machine (SVM) and Random Forest (RF), with the objective of determining the optimal choice when implementing them on limited computing devices. This study shows SVM and RF both have high accuracy values, 82% and 73%, respectively. Both of them also have fast computation times, with average inference times of 2.14 seconds and 2.15 seconds, respectively. The average CPU usage in the SVM algorithm is higher compared to the RF algorithm, at 17.80% and 15.48%. Eventhough SVM has higher accuracy rate, better precision, recall, and f score, but after conducting an independent 2-samples t-test on the inference time and CPU usage, it was found that there is no significant difference between SVM and RF. Both has good performance and good classification.

¹ Departemen Ilmu Komputer, FMIPA IPB;

² Departemen Agronomi dan Hortikultura, FAPERTA IPB;

* Penulis Korespondensi: my_juni04@apps.ipb.ac.id

The RF algorithm is recommended because it has a good accuracy rate, fast computation time, and less CPU resource usage.

Keywords: limited computing device, machine learning, melon fruit, random forest, support vector machine

PENDAHULUAN

Melon (*Cucumis melo* L.) terdiri atas sejumlah kelompok varietas botani. Di Indonesia, terdapat tiga kelompok varietas yang populer dan umum dibudidayakan yaitu *reticulatus*, *inodorus*, dan *cantalupensis*. *Reticulatus* merupakan kelompok varietas melon dengan buah berbentuk bulat atau lonjong, kulit umumnya berwarna hijau muda atau hijau tua, dan permukaannya memiliki tekstur seperti jala atau mirip jaring. Sedangkan, *inodorus* merupakan kelompok varietas melon dengan permukaan buah yang halus tanpa jala, dan umumnya berwarna kuning atau putih dengan bentuk yang bulat hingga lonjong. Melon *cantalupensis* yang terkenal di Indonesia memiliki juring, dan dagingnya berwarna kuning atau oranye (Huda *et al.* 2019). Karakteristik buah melon unggul yang diinginkan konsumen adalah yang memiliki rasa manis, harga murah, daging yang renyah, ukuran buah yang sedang atau besar, beraroma kuat, dan tahan simpan (Makful *et al.* 2018). Kualitas dan nilai jual produk tersebut dipengaruhi oleh tingkat kematangan saat melon dipanen dan sampai kepada konsumen. Oleh karena itu, menemukan waktu panen yang tepat dan masa simpan yang optimal menjadi kunci dalam memperoleh kualitas terbaik dari buah melon.

Umur simpan buah dipengaruhi sejumlah faktor diantaranya stadia kematangan (Mutton *et al.* 1981). Stadia kematangan sendiri berhubungan dengan padatan terlarut total dan bobot buah. Penelitian dengan judul "Karakteristik Buah Melon (*Cucumis melo* L.) pada Lima Stadia Kematangan" (Huda *et al.* 2019) membuat sebuah permodelan karakteristik buah untuk memprediksi peningkatan karakter buah dalam setiap kenaikan stadia. Dari penelitian tersebut didapatkan kesimpulan bahwa stadia kematangan memiliki pengaruh yang penting bagi kualitas dan umur simpan buah. Pada kelompok melon *inodurus*, karakter morfologi buah terbaik adalah ketika warna buah kuning cerah dan permukaannya halus saat stadia kematangan ke-5. Sedangkan untuk kelompok melon *reticulatus*, kriteria panen terbaik yaitu pada stadia kematangan ke-5 saat jala memiliki intensitas yang banyak, distribusi jalanya merata, dan tangkai buah yang hampir terlepas menandakan bahwa buah sudah matang dan siap dipanen. Stadia kematangan buah melon sampai saat ini masih dilakukan dengan cara konvensional yaitu dengan perhitungan hari tanam, melihat warna kulit buah, melihat intensitas jala, melihat tangkai buah, atau dengan uji coba konsumsi buah sebagai indikator kematangan yang tepat sebelum dilakukan proses panen. Proses penentuan kematangan buah melon secara konvensional dapat memakan waktu, membutuhkan keahlian yang tinggi, rentan terhadap kesalahan subjektif, dan memperlambat efisiensi produksi. Dengan demikian dibutuhkan sebuah sistem otomasi deteksi kematangan buah yang bersifat akurat dan cepat yaitu dengan melibatkan robot pengawas pertanian (Budiarti *et al.* 2021). Rangkaian riset pengembangan robot pengawas pertanian (*surveillance robot*) yang sudah ada diantaranya adalah deteksi kelainan daun tanaman melon menggunakan metode *deep learning* (Rahmat *et al.* 2022), *object detection* untuk pruning buah melon (Budiarti *et al.* 2021), dan *decision support system* untuk deteksi waktu panen pada buah melon dengan menggunakan metode ekstraksi ciri warna kulit buah (AL-dilphi *et al.* 2021). Dari riset yang sudah ada, dapat dilakukan penelitian lanjutan terkait deteksi waktu panen namun pada kelompok buah melon berjala (*C. melo* var. *reticulatus*). Dalam mencapai akurasi yang tinggi, sistem otomasi ini membutuhkan pendekatan *machine learning* agar mampu mengidentifikasi dengan tepat buah yang telah matang dan siap dipanen.

Penelitian mengenai pengembangan metode deteksi tingkat kematangan buah melon dengan pendekatan *machine learning* salah satunya dilakukan oleh Prayoga *et al.* (2018) dengan menggunakan metode ekstraksi ciri statistik dan *Support Vector Machine* (SVM). Penelitian tersebut mengaplikasikan fitur tekstur kulit berjala pada buah melon sebagai variabel utama dan hasilnya mencapai tingkat akurasi sebesar 76% dengan mengklasifikasikan buah melon

ke dalam tiga kelas yaitu tidak matang, setengah matang, dan matang. Tahapan proses yang dilakukan meliputi konversi informasi RGB pada citra menjadi citra *grayscale*, perbaikan *noise* dengan menggunakan median *blur*, penerapan *adaptive threshold* untuk menghasilkan bentuk histogram dan nilai-nilainya dimasukkan ke dalam sebuah *array* untuk dilatih menggunakan metode SVM (Prayoga *et al.* 2018). Penelitian lain dengan metode yang serupa namun ekstraksi ciri yang berbeda dilakukan oleh Saputra *et al.* (2022) yaitu mendeteksi kematangan buah melon dengan metode SVM berbasis ekstraksi fitur *Gray Level Co-occurrence Matrix* (GLCM). GLCM merupakan sebuah metode analisis tekstur dengan menghitung probabilitas hubungan antara sepasang piksel dengan intensitas jarak dan sudut tertentu (Saputra *et al.* 2020). Lima fitur GLCM yang digunakan adalah *correlation*, *homogeneity*, *contrast*, *ASM*, dan energi. Selain analisa tekstur, penelitian tersebut membandingkan empat arah sudut dan delapan arah sudut GLCM serta membandingkan empat fungsi kernel pada SVM yaitu linear, *polynomial*, sigmoid, dan *Radial Basis Function* (RBF). Hasil terbaik yang didapatkan adalah menggunakan fungsi kernel linear dan delapan arah sudut GLCM dengan nilai akurasi 80%, nilai *precision* 81%, dan nilai *recall* 80% (Saputra *et al.* 2022). Metode *machine learning* lain yang pernah dilakukan untuk memprediksi tingkat kematangan buah adalah penelitian oleh Elhariri *et al.* (2014) yaitu membandingkan SVM dan *Random Forest Classifier* (RF) untuk deteksi kematangan tanaman tomat dan paprika. Penelitian tersebut menunjukkan bahwa SVM dengan kernel linear memiliki nilai akurasi yang lebih tinggi dibandingkan dengan RF dengan catatan bahwa RF mungkin akan memiliki akurasi yang lebih baik jika dilatih dengan data yang lebih banyak.

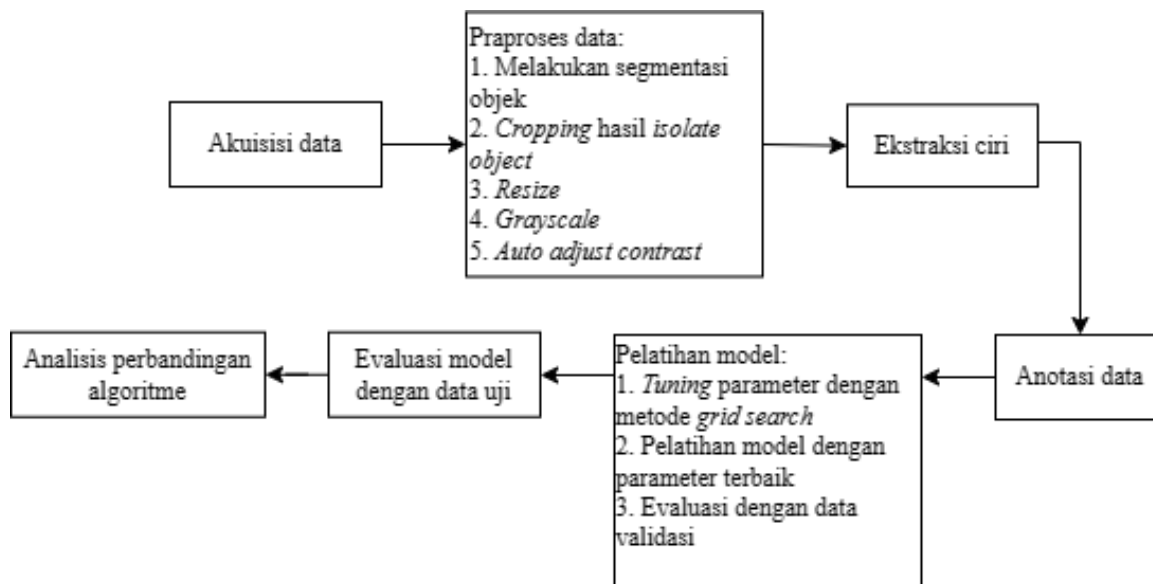
Meninjau dari penelitian yang telah disebutkan, dapat dilakukan penelitian lanjutan untuk mendeteksi stadia kematangan buah melon menggunakan citra tekstur kulit buah dan ekstraksi ciri GLCM. Penelitian ini bertujuan untuk mengimplementasikan SVM dan RF pada sistem robot pengawas pertanian dengan perangkat komputasi terbatas. Namun demikian, perangkat komputasi terbatas memiliki kekurangan yaitu *trade-off* antara akurasi yang tinggi dengan waktu komputasi dan penggunaan sumberdaya karena prosesornya hanya terdiri dari *single-core* dan jumlah *Random Access Memory* (RAM) yang terbatas (Foley dan O'Reilly 2018). Rahmat *et al.* (2022) melakukan perbandingan analisis *object detection* antara tiga buah metode *deep learning* untuk diimplementasikan pada perangkat komputasi terbatas yaitu Raspberry Pi. Penelitian tersebut menyimpulkan bahwa algoritma terbaik untuk diterapkan di perangkat komputasi terbatas adalah algoritma yang memiliki *mean average precision* (mAP) tinggi, waktu komputasi (*inference time*) yang cepat, serta penggunaan sumberdaya CPU dan *Resident Set Size* (RSS) yang rendah. Referensi tersebut dapat digunakan sebagai landasan untuk membandingkan dan mengevaluasi kinerja antara algoritma SVM dan RF untuk diimplementasikan pada perangkat komputasi terbatas.

METODE

Data yang digunakan adalah citra melon berjala yaitu varietas *Sakata Glamour* yang dibudidayakan di agrowisata Kampung Melon yang terletak di Kampung Sabang Kulon, Desa Sukajaya, Sukabumi. Tahapan penelitian ini mengacu pada penelitian yang sudah dilakukan sebelumnya oleh Rahmat *et al.* (2022). Tahapan tersebut mencakup akuisisi data, praproses data, ekstraksi ciri, anotasi data, pelatihan model, dan evaluasi model, dapat dilihat pada Gambar 1.

Akuisisi Data

Data pada penelitian ini berupa citra yang diambil menggunakan kamera khusus RGB-D *Intel Real Sense*. Penelitian bertempat di sebuah kawasan agrowisata Kampung Melon milik *Organization for Industrial, Spiritual and Cultural Advancement* (OISCA). Pengambilan data dilakukan setiap hari sejak hari tanam ke-45 sampai hari panen (dimulai pukul 09.00 WIB sampai dengan selesai). Merujuk pada penelitian Budiarti *et al.* (2021), tiga buah sudut penangkapan citra diambil untuk setiap satu buah melon. Pertama dari depan buah, kedua dari samping dengan sudut 45°, dan yang terakhir dari samping dengan sudut 90°.



Gambar 1 Tahapan penelitian

Praproses Data

Tahap praproses data yang dilakukan pada penelitian ini meliputi enam langkah yaitu menentukan *bounding box* objek, *cropping* dengan melakukan isolasi objek sebesar daerah *bounding box*, merubah ukuran citra menjadi 416 x 416 piksel, merubah citra dari RGB menjadi *grayscale*, melakukan *auto adjust contrast*, dan terakhir melakukan augmentasi pada beberapa citra. Total 1490 citra yang didapatkan dibagi menjadi dua yaitu 1430 citra untuk pelatihan model dan 60 citra untuk data uji. Dari 1430 citra untuk pelatihan model, 80% citra digunakan sebagai data latih dan 20% citra digunakan sebagai data validasi. Dari 1430 citra dibagi juga menjadi dua kelas, 645 citra masuk ke dalam kelas belum matang dan 785 citra masuk ke dalam kelas siap panen. 60 citra data uji digunakan untuk mengevaluasi model *machine learning* yang dihasilkan. Pemilihan 60 citra data uji dilakukan secara acak dengan memperhatikan representasi setiap kelas. Merujuk pada penelitian Budiarti *et al.* (2021), pengecilan citra dilakukan dengan merubah ukuran citra menjadi 416 x 416 piksel agar beban komputasi lebih ringan dan seluruh citra memiliki ukuran yang sama. Tahap selanjutnya adalah mentransformasi citra RGB menjadi citra *grayscale* yaitu dengan menghilangkan informasi warna pada citra dan menggantinya dengan nilai intensitas kecerahan gradasi keabuan yang umumnya berkisar antara 0 (hitam) hingga 255 (putih).

Praproses kelima adalah pengaplikasian metode *auto adjust contrast* untuk secara otomatis meningkatkan ketajaman dan detail citra sehingga alur jala pada permukaan kulit buah melon dapat terlihat dengan jelas dan perhitungan kepadatan jala dapat dilakukan dengan menghitung piksel putih pada citra. Tahapan terakhir dengan alasan ketidakseimbangan jumlah dataset citra untuk pemodelan, maka dilakukan proses augmentasi untuk kelas belum matang yaitu *flip* horizontal, *flip* vertikal, rotasi objek sebesar 45°, dan rotasi objek sebesar 90° masing-masing sebanyak 100 buah citra.

Ekstraksi Ciri

Merujuk pada penelitian oleh Alqoria dan Utaminingrum (2021) ekstraksi ciri yang cocok untuk deteksi kematangan buah melon dengan perbandingan tekstur adalah dengan metode ekstraksi ciri *Gray Level Co-occurrence* (GLCM). Fitur ekstraksi yang digunakan dalam penelitian ini adalah *contrast*, energi, *homogeneity*, *correlation*, dan *dissimilarity*. Persamaan kelima fitur dapat dilihat pada Persamaan 1, Persamaan 2, Persamaan 3, Persamaan 4, dan Persamaan 5 secara berurutan. GLCM direpresentasikan sebagai matriks dengan i dan j sebagai pasangan piksel baris i dan kolom j .

$$\sum_i \sum_j (i-j)^2 p(i,j) \tag{1}$$

$$\sum_i \sum_j p(i,j)^2 \tag{2}$$

$$\sum_i \sum_j \frac{p(i,j)}{1+|i-j|} \tag{3}$$

$$\sum_i \sum_j \frac{(i-\mu)(j-\mu)p(i,j)}{\sigma^2} \tag{4}$$

$$\sum_i \sum_j |i-j| \times p(i,j) \tag{5}$$

Contoh perhitungan matriks GLCM diilustrasikan pada Gambar 2, Gambar 3, dan Gambar 4. Matriks GLCM didapatkan dengan cara membentuk matriks awal dari pasangan dua buah piksel dengan arah 0° kemudian matriks tersebut ditransformasi menjadi matriks simetris (Gambar 3) dengan cara menjumlahkan matriks (Gambar 2) dengan matriks transposnya (Rizal *et al.* 2019). Matriks pada Gambar 3 dinormalisasi membagi nilai piksel setiap elemen dengan jumlah total nilai piksel dalam matriks tersebut. Selanjutnya dapat dilakukan ekstraksi fitur dengan menghitung setiap fitur dengan persamaan matematika masing-masing. Salah satu contoh perhitungan fitur GLCM yaitu energi dapat dilihat pada Persamaan 6 (Aferi *et al.* 2018).

Dua buah fitur lain ditambahkan dengan tujuan mendapatkan hasil yang lebih akurat. Dua fitur tersebut adalah jumlah piksel jala dan kepadatan piksel jala. Jumlah piksel jala dihitung dengan mengidentifikasi dan menghitung nilai piksel 255 atau warna putih pada citra. Sedangkan kepadatan piksel jala dihitung dengan membagi jumlah piksel jala dengan luas area objek buah melon. Kedua fitur ini memberikan informasi kerapatan dan intensitas jala, yaitu semakin rapat jalanya semakin matang dan siap untuk dipanen (Huda *et al.* 2019).

GLCM (i)	Matrix Co-occurrence (j)				
	0	1	2	3	4
0	2	2	0	0	0
1	1	1	0	0	0
2	0	0	0	0	0
3	0	0	0	0	2
4	0	0	0	1	2

Gambar 2 Contoh matriks GLCM (Aferi *et al.* 2018)

GLCM (i)	Matrix Co-occurrence (j)				
	0	1	2	3	4
0	4	3	0	0	0
1	3	2	0	0	0
2	0	0	0	0	0
3	0	0	0	0	3
4	0	0	0	3	3

Gambar 3 Matrix Co-occurrence probabilities (Aferi *et al.* 2018)

GLCM (i)	Matrix Co-occurrence (j)				
	0	1	2	3	4
0	0.1904	0.1428	0	0	0
1	0.1428	0.0952	0	0	0
2	0	0	0	0	0
3	0	0	0	0	0.1428
4	0	0	0	0.1428	0.1428

Gambar 4 Matriks hasil normalisasi

$$Energy = (0.1904)^2 + (0.1428)^2 + \dots + (0.1428)^2 = 0.1464 \tag{6}$$

Anotasi Data

Anotasi data dilakukan dengan cara memberi label kelas untuk mengklasifikasikan terlebih dahulu data-data yang dimiliki sehingga menghasilkan pemodelan yang akurat. Klasifikasi dilakukan secara manual dengan melabeli setiap baris *dataframe* yang berisi fitur GLCM, jumlah piksel jala, dan nilai kerapatan jala sesuai dengan kelasnya, yaitu belum matang dan siap panen.

Pelatihan Model

Proses pelatihan model dimulai dengan memuat *dataframe* yang berisi fitur-fitur yang akan digunakan dalam pemodelan. Atribut pada fitur-fitur tersebut memiliki skala yang berbeda mengakibatkan kinerja model dan komputasi menjadi tidak efisien. Data dinormalisasi menggunakan teknik *Z-score* dengan tujuan menyeragamkan skala, meningkatkan kinerja model, dan meningkatkan efisiensi komputasi. Dataset berisi 1430 data dibagi menjadi data latih dan data validasi dengan rasio 0.8:0.2. *Tuning* parameter pada pemodelan SVM mencakup tiga parameter yaitu dua jenis kernel, linear dan *Radial Basis Function* (RBF), nilai toleransi kesalahan klasifikasi pada data latih atau nilai C (0,1, 1, 10), dan nilai gamma (0,1,1, 10). Nilai parameter terbaik dicari menggunakan teknik *grid search* yaitu sebuah teknik yang menerapkan berbagai kombinasi parameter sehingga menghasilkan kinerja model yang optimal. Pada RF, *tuning* parameter mencakup tiga parameter yaitu kedalaman maksimal (5, 10, 15), jumlah pohon keputusan yang dibangun (100, 200, 300), dan nilai minimum jumlah sampel untuk membagi node menjadi node dua anak (5, 10, 15). Proses pencarian nilai parameter terbaik dilakukan melalui metode *grid search* juga diterapkan pada algoritma SVM. Parameter-parameter terbaik yang dihasilkan oleh *grid search* digunakan sebagai dasar untuk melakukan pemodelan. Seluruh langkah pemodelan ini dilakukan menggunakan Google Colab. Setelah pemodelan menggunakan kedua algoritma dibuat, langkah selanjutnya adalah menguji model keduanya dengan data validasi.

Evaluasi Model

Evaluasi model SVM dan RF dilakukan dengan menguji model menggunakan 60 data uji yang tidak pernah dilatih oleh model. Proses ini bertujuan untuk mengevaluasi kinerja model dan mengukur tingkat akurasi kedua model algoritma dalam memprediksi kelas data baru. Akurasi diukur dengan menghitung *confusion matrix*, *precision*, *recall*, dan *average precision recall*. Perangkat komputasi terbatas hanya terdiri dari prosesor *single-core* dan RAM yang terbatas. Merujuk pada penelitian Rahmat *et al.* (2022), konsumsi sumberdaya CPU dan *inference time* digunakan untuk mengevaluasi kinerja algoritma pada perangkat komputasi terbatas. Perangkat komputasi terbatas memiliki resiko *overheating*, penurunan kinerja, hingga kerusakan *hardware* yang lebih tinggi jika terjadi beban kinerja berlebih karena keterbatasan prosesor dan RAM. Model yang menghasilkan akurasi tinggi akan semakin baik jika disertai dengan konsumsi sumberdaya dan waktu *inference* yang rendah. Pengukuran *inference time* dan konsumsi sumberdaya CPU dilakukan dengan cara mencari rata-rata waktu komputasi dan persentase penggunaan CPU dalam sepuluh kali *running* sistem.

HASIL DAN PEMBAHASAN

Akuisisi Data






Citra hasil akuisisi diklasifikasikan ke dalam dua kelas yaitu belum matang dan siap panen. Proses ini dilakukan secara manual dengan bantuan konsultasi dari pembimbing sebagai panduan. Merujuk pada penelitian oleh Huda *et al.* (2019) mengenai pengklasifikasian lima stadia kematangan buah, maka pada penelitian ini stadia 1, 2, 3, dan 4 dikategorikan ke dalam kelas belum matang. Sedangkan stadia 5 dikategorikan ke dalam kelas siap panen. Untuk mendapatkan hasil pemodelan yang optimal, buah melon yang tidak termasuk ke dalam stadia

kematangan lima diklasifikasikan ke dalam kelas belum matang dengan tujuan model terhindar dari salah klasifikasi ketika buah berada pada fase perpindahan antara stadia empat menuju stadia lima. Deskripsi tiap stadia kematangan buah melon dan pembagian klasifikasi pada penelitian ini dapat dilihat pada Tabel 1.


Praproses Data

Enam tahapan praproses data dapat dilihat pada Gambar 5 dan tahapan augmentasi dapat dilihat pada Gambar 6. Tahapan praproses dilakukan dengan menggunakan *tools* Roboflow sedangkan tahapan augmentasi dilakukan secara manual menggunakan program python. Pada segmentasi objek dengan Roboflow, dilakukan proses *smart polygon annotation* dan *auto adjust contrast*. *Smart polygon annotation* yaitu penandaan objek otomatis menggunakan poligon yang berupa rangkaian titik-titik koordinat yang membentuk batas objek. Algoritma deteksi objek yang digunakan untuk *smart polygon annotation* ini adalah YOLOv5 *Instance Segmentation*. Sedangkan *auto adjust contrast* menggunakan teknik pemerataan adaptif *Contrast Limited Adaptive Histogram Equalization (CLAHE)*.


Tabel 1 Pembagian kelas berdasarkan deskripsi morfologi stadia kematangan buah melon

Stadia Satu	Stadia dua	Stadia tiga	Stadia empat	Stadia lima
				
Kelas belum matang	Kelas belum matang	Kelas belum matang	Kelas belum matang	Kelas siap panen
Tidak terdapat jala pada permukaan buah	Terdapat sedikit jala pada permukaan buah	Terdapat jala dengan intensitas sedang	Terdapat jala dengan intensitas banyak	Terdapat jala dengan intensitas banyak dan distribusi jala merata pada seluruh permukaan buah

Keterangan: deskripsi pada setiap stadia kematangan diambil dari Huda *et al.* (2019)



Gambar 5 Tahapan praproses data; (a) citra asli, (b) *bounding box*, (c) *cropping*, (d) *resize*, (e) *grayscale*, (f) *auto adjust contrast*



Gambar 6 Empat jenis augmentasi citra; (a) *flip* horizontal, (b) *flip* vertical, (c) *rotate* 45°, dan (d) *rotate* 90°

Ekstraksi Ciri

Ekstraksi ciri dilakukan menggunakan GLCM. Perhitungan nilai jumlah piksel jala, dan kepadatan piksel jala diaplikasikan kepada semua citra baik itu data latih, data validasi, maupun data uji. Nilai-nilai variabel tersebut dimasukkan ke dalam array dan disatukan dalam sebuah *dataframe* kemudian dinormalisasi.

Anotasi Data

Anotasi data atau proses pelabelan kelas dilakukan secara manual setelah proses normalisasi. Nilai 1 digunakan sebagai representasi simbolik kelas belum matang dan nilai 0 digunakan sebagai representasi nilai siap panen. Contoh hasil anotasi dapat dilihat pada Tabel 2

Pelatihan Model

Teknik *grid search* menunjukkan bahwa parameter terbaik untuk algoritma SVM adalah nilai C 1 dan kernel linear. Karena menggunakan kernel linear maka nilai gamma tidak diperlukan. Sementara itu, parameter terbaik untuk algoritma RF adalah kedalaman maksimal 10, jumlah pohon keputusan yang akan dibangun 300, dan nilai minimum jumlah sampel untuk membagi node menjadi node dua anak adalah 5. Hasil pemodelan diuji dengan data validasi. Akurasi untuk model SVM sebesar 88.46% dan akurasi untuk model RF sebesar 88.11%. Dilihat dari *confusion* matrix, SVM mengklasifikasikan secara akurat 146 citra siap panen (*true negative*) dan 107 citra belum matang (*true positive*). Sebanyak 18 citra belum matang mengalami salah prediksi (*false negative*) dan sebanyak 15 citra siap panen masuk ke dalam kelas belum matang (*false positive*). RF mengklasifikasikan secara akurat 150 citra siap panen (*true negative*) dan 102 citra belum matang (*true positive*), sedangkan 23 citra belum matang masuk ke dalam kelas siap panen (*false negative*) 11 citra siap panen masuk ke dalam kelas belum matang (*false negative*). Kepentingan fitur juga dihitung untuk mengukur seberapa penting hubungan fitur tersebut terhadap hasil prediksi. Kepentingan fitur-fitur pada pemodelan SVM adalah kepadatan piksel jala (98%), *homogeneity* (98%), jumlah piksel jala (42%), *correlation* (27%), *energy* (19%), *dissimilarity* (-98%), dan *contrast* (-98%). *Dissimilarity* dan *contrast* memiliki nilai kepentingan fitur negatif yang sangat besar sehingga memungkinkan fitur-fitur tersebut memiliki pengaruh negatif terhadap hasil prediksi. Sementara itu, kepentingan fitur pada pemodelan RF adalah *contrast* (27%), *homogeneity* (18%), *dissimilarity* (15%), *energy* (13%), kepadatan piksel jala (13%), jumlah piksel jala (11%), dan *correlation* (3%).

Tabel 2 Contoh anotasi data

No	Contrast	Energy	Homogeneity	Correlation	Dissimilarity	Jumlah piksel jala	Kepadatan piksel jala	Kelas
1	-1,0833	1,0454	1,0833	-0,1420	-1,0833	-1,0021	-1,0016	1
2	-0,9103	0,8322	0,9104	1,4566	-0,9104	-0,7607	-0,7614	1
3	-0,5683	0,4715	0,5683	1,4515	-0,5683	-0,3919	-0,3904	1
4	1,7930	-1,7164	-1,7930	0,0344	1,7930	1,6433	1,6429	0
5	1,1707	-1,1509	-1,1707	0,2462	1,1707	1,1203	1,1198	0
6	0,1738	-0,1291	-0,1739	-0,3619	0,1739	0,0909	0,0903	0

Evaluasi Model

Confusion matrix dihitung untuk mengukur *precision*, *recall*, dan *f-score*. Matriks hasil uji kedua model dapat dilihat pada Tabel 3. Akurasi hasil uji kedua model yaitu SVM 82% dan akurasi model RF adalah 73%. *Precision* adalah ukuran evaluasi untuk melihat seberapa positif pengaruh model terhadap prediksi dengan membagi *True Positive* dengan jumlah seluruh data yang diprediksi positif (*true positive* ditambah *false positive*). Akurasi SVM dan RF tidak sempurna namun memiliki nilai *precision* 100% artinya kedua model ini memiliki tingkat kesalahan *false positive* (FP) yang sangat rendah bahkan tidak ada. *Recall* adalah ukuran evaluasi untuk menilai kemampuan model untuk mengingat kasus positif yang benar merupakan positif. Cara menghitungnya adalah dengan membagi nilai *true positive* dengan jumlah *true positive* dan *false negative*. Nilai *recall* kedua algoritma ini adalah 72.5% untuk SVM dan 60% untuk RF. *F-score* dicari untuk melihat ukuran seberapa harmonis hubungan antara *precision* dan *recall* dengan menghitung kemampuan identifikasi kelas positif dengan benar dan mengurangi kesalahan dalam memprediksi kelas positif palsu (*false positive*) serta kelas negatif palsu (*false negative*). Nilai yang didapatkan adalah 0.84 pada SVM dan 0.75 pada RF.

Kedua algoritma, SVM dan RF sama-sama memiliki nilai akurasi yang tinggi yaitu 82% dan 73%, *inference time* keduanya juga memiliki rata-rata waktu komputasi yang cepat yaitu 2.14 detik dan 2.15 detik. Konsumsi sumberdaya CPU dilakukan dengan cara memantau pemakaian CPU selama program berjalan setiap 0.25 detik sebanyak sepuluh kali *running* sistem yang dapat dilihat pada Tabel 4. Hasilnya adalah konsumsi pemakaian CPU pada algoritma SVM sedikit lebih besar dibandingkan dengan algoritma RF, yaitu 17.80% untuk SVM dan 15.48% untuk RF.

Meninjau dari tingkat akurasi yang baik, waktu komputasi cepat, penggunaan sumberdaya CPU, serta *precision*, *recall*, dan *f-score* yang terkategori ke dalam *good classification*, maka algoritma RF menjadi algoritma yang disarankan untuk diimplementasikan pada perangkat komputasi terbatas.

Tabel 3 Perbandingan *confusion matrix* hasil uji SVM dan RF

	SVM		RF	
	Belum matang	Siap panen	Belum matang	Siap panen
Prediksi belum matang	29	0	24	0
Prediksi siap panen	11	20	16	20

Tabel 4 Waktu komputasi dan penggunaan CPU

Percobaan ke-	SVM		RF	
	<i>Inference time</i> (detik)	Penggunaan CPU (%)	<i>Inference Time</i> (detik)	Penggunaan CPU (%)
1	2.17	17.80	2.28	20.60
2	2.06	23.50	2.00	13.70
3	1.90	13.20	2.18	15.30
4	2.22	19.00	2.29	16.24
5	2.08	20.65	2.13	16.90
6	2.26	16.58	2.03	20.87
7	2.43	16.16	2.30	11.14
8	2.12	14.40	2.14	12.37
9	2.07	20.27	2.15	12.62
10	2.06	16.47	2.05	15.05
Rata-rata	2.14	17.80	2.15	15.48

Tabel 5 Perbandingan SVM dan RF

No.	Perbandingan	SVM	RF
1	Akurasi	82%	73%
2	Precision	100%	100%
3	Recall	72.50%	60%
4	F-score	0.84	0.75
5	Inference time	2.14 detik	2.15 detik
6	Penggunaan CPU	17.80%	15.48%

SIMPULAN

Pemodelan berbasis *machine learning* untuk deteksi stadia kematangan *Cucumis melo* var. *reticulatus* dengan menggunakan algoritma SVM dan RF memiliki hasil tidak berbeda nyata. Namun, dengan mempertimbangkan tingkat akurasi, *inference time*, dan penggunaan sumberdaya CPU, algoritma yang disarankan untuk diimplementasikan pada perangkat komputasi terbatas adalah algoritma RF. Meskipun secara tingkat akurasi SVM lebih tinggi dari RF dan *inference time* keduanya tidak berbeda jauh, namun RF menggunakan sumberdaya yang lebih rendah dibandingkan dengan SVM. Penggunaan sumberdaya CPU menjadi faktor yang penting untuk dipertimbangkan karena perangkat komputasi terbatas memiliki prosesor *single-core*. Selain itu, tingkat akurasi, *precision*, *recall*, dan *f-score* menunjukkan RF masuk dalam kategori algoritma yang baik untuk mendeteksi stadia kematangan *Cucumis melo* var. *reticulatus*.

DAFTAR PUSTAKA

- Aferi FD, Purboyo TW, Saputra RE. 2018b. Cotton Texture Segmentation Based On Image Texture Analysis Using Gray Level Co-occurrence Matrix (GLCM) And Euclidean Distance. *International Journal of Applied Engineering Research*. 13(1):449–455. [diakses 2023 Agu 7]. https://www.ripublication.com/ijaer18/ijaerv13n1_61.pdf.
- AL-dilphi JM, Wahjuni S, Suwarno W. 2021. Decision Support System for in situ melon's Fruit harvesting time based on Fuzzy Logic and Single Shot Detector (SSD). Di dalam: *Proceedings of the World Congress on Engineering*; 2021 Jul 7-9. London, UK. London: hlm 83-90; [diunduh 2023 Jul 10]. https://www.iaeng.org/publication/WCE2021/WCE2021_pp83-90.pdf
- Alqoria NT, Utaminigrum F. 2021. Rancang Bangun Sistem Deteksi Kemanisan Buah Melon Menggunakan Gray Level Co-occurrence Matrix dan Support Vector Machine. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*. 5(6):2472–2477. [diakses 2023 Agu 10]. <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/9250>.
- Budiarti NAE, Wahjuni S, Suwarno WB, Wulandari. 2021. Research on Melon Fruit Selection Based on Rank with YOLOv4 Algorithm. *J Phys Conf Ser*. 2123(1):012036. doi:10.1088/1742-6596/2123/1/012036.
- Elhariri E, El-Bendary N, Hassanien AE, Badr A, Hussein AMM, Snášel V. 2014. Random Forests Based Classification for Crops Ripeness Stages. Di dalam: *Proceedings of the Fifth International Conference on Innovations in Bio-Inspired Computing and Applications IBICA*. Volume ke-303. Springer Verlag. hlm 205–215.
- Foley D, O'Reilly R. 2018. An evaluation of convolutional neural network models for object detection in images on low-end devices. Di dalam: *Conference: Proceedings for the 26th Irish Conference on Artificial Intelligence and Cognitive Science*. Volume ke-2259. Dublin, Ireland.
- Huda AN, Suwarno WB, Maharijaya DA. 2019. Karakteristik Buah Melon (*Cucumis melo* L.) pada Lima Stadia Kematangan. *Jurnal Agronomi Indonesia (Indonesian Journal of Agronomy)*. 46(3). doi:10.24831/jai.v46i3.12660.

- Makful N, Hendri N, Sahlan N. 2018. Evaluasi Dua Calon Varietas Unggul Melon di Sumatera Barat, Jawa Barat dan Jawa Timur. *Jurnal Hortikultura*. 27(2):185. doi:10.21082/JHORT.V27N2.2017.P185-194.
- Mutton LL, Cullis BR, Blakeney AB. 1981. The objective definition of eating quality in rockmelons (*Cucumis melo*). *J Sci Food Agric*. 32(4). doi:10.1002/jsfa.2740320412.
- Prayoga A, Tawakal HA, Aldiansyah R. 2018. Pengembangan Metode Deteksi Tingkat Kematangan Buah Melon Berdasarkan Tekstur Kulit Buah Dengan Menggunakan Metode Ekstraksi Ciri Statistik Dan Support Vector Machine (Svm). *Jurnal Teknologi Terpadu*. 4(1). doi:10.54914/jtt.v4i1.112.
- Rahmat H, Wahjuni S, Rahmawan H. 2022. Performance Analysis of Deep Learning-based Object Detectors on Raspberry Pi for Detecting Melon Leaf Abnormality. *Int J Adv Sci Eng Inf Technol*. 12(2):572. doi:10.18517/ijaseit.12.2.13801.
- Rizal RA, Gulo S, Della O, Sihombing C, Bernandustahi A, Napitupulu M, Gultom AY, Siagian TJ. 2019. Analisis Gray Level Co-Occurrence Matrix (GlcM) Dalam Mengenali Citra Ekspresi Wajah. Volume ke-3. <https://iocscience.org/ejournal/index.php/mantik/index>.
- Saputra RA, Puspitasari D, Baidawi T. 2022. Deteksi Kematangan Buah Melon Dengan Algoritma Support Vector Machine Berbasis Ekstraksi Fitur GLCM. *Jurnal Infortech*. 4(2):200–206. doi:10.31294/INFORTECH.V4I2.14436.
- Saputra RA, Wasiyanti S, Saefudin DF, Supriyatna A, Wibowo A. 2020. Rice Leaf Disease Image Classifications Using KNN Based On GLCM Feature Extraction. *J Phys Conf Ser*. 1641:12080. doi:10.1088/1742-6596/1641/1/012080.