TELKA: Jurnal Telekomunikasi, Elektronika, Komputasi, dan Kontrol
Vol. 12, No. 2, July 2026, pp. 247-262
ISSN (e): 2540-9123 ISSN (p): 2502-1982
DOI: https://doi.org/10.15575/telka.v12n2.247-262

Perbandingan Metode K-NN, SVM, Decision Tree, dan MLP dalam Klasifikasi Kualitas Sayur Segar dan Sayur Tidak Segar

Daniel Sutopo Pamungkas[1]*, Ana Safitri Kania[2], Vany Nuroh Mawati[3]
[1,2,3]Jurusan Teknik Elektro, Politeknik Negeri Batam, Batam, Indonesia
daniel@polibatam.ac.id[1]*, anasftri24@gmail.com[2], vanynurohmawati@gmail.com[3]

Article Info

Riwayat artikel:
Diterima: 30 Juni 2026
Direvisi: 9 Februari 2026
Disetujui: 8 Mei 2026
Dipublikasi: Juli 2026

Keywords:
Decision Tree, K-Nearest Neighbors (K-NN);
Klasifikasi kesegaran sayur;
Multi-Layer Perceptron (MLP);
Support Vector Machine (SVM).

ABSTRAK

Ketersediaan sayuran dengan kualitas yang tinggi memiliki peran penting dalam mendukung kebutuhan nutrisi yang seimbang. Salah satu upaya untuk menjamin kualitas sayuran tersebut adalah dengan mengidentifikasi karakteristik fisik dan kimiawi dari masing-masing jenis sayuran. Penelitian ini bertujuan untuk mengklasifikasikan kualitas kesegaran sayur dengan menggunakan gambar yang dimasukkan ke dalam folder sebagai dataset. Empat metode klasifikasi, yaitu *K-Nearest Neighbors* (K-NN), *Support Vector Machine* (SVM), *Decision Tree*, dan *Multi-Layer Perceptron* (MLP) digunakan untuk membangun model klasifikasi. Pengujian dilakukan terhadap tiga jenis sayuran, yaitu bawang merah, brokoli, dan wortel dengan dua kategori: segar dan tidak segar. Hasil penelitian menunjukkan bahwa metode MLP memberikan performa terbaik dengan nilai *accuracy* 79,17%, *precision* 83,33%, *recall* 79,17%, dan *F1-score* sebesar 77,97%. Sementara itu, metode SVM mencapai accuracy 77,50%, metode K-NN mencapai *accuracy* 70,83% dan *Decision Tree* mencapai accuracy 40,83%. Dari hasil tersebut, dapat disimpulkan bahwa metode MLP lebih unggul dalam klasifikasi kualitas sayur dibandingkan dengan metode SVM, K-NN dan *Decision Tree*. Pengembangan *real-time* lebih lanjut diusulkan untuk menerapkan sistem deteksi *real-time* dan uji coba di lingkungan nyata.

Corresponding Author:
Daniel S Pamungkas,
Jurusan Teknik Elektro, Politeknik Negeri Batam
daniel@polibatam.ac.id

1. PENDAHULUAN

Sayuran merupakan bagian integral dari pola makan sehat dan keseimbangan gizi manusia. Ketersediaan sayuran yang segar dan berkualitas tinggi sangat penting dalam mendukung asupan nutrisi yang seimbang [1]. Salah satu aspek penting dalam memastikan kualitas sayuran adalah memahami karakteristik fisik dan kimiawi dari masing-masing jenis sayuran. Penelitian tentang klasifikasi kesegaran sayuran menjadi hal yang relevan dan penting. Tanaman sayuran seperti brokoli, wortel, dan bawang merah memiliki perbedaan dalam morfologi, komposisi nutrisi, serta faktor-faktor lain yang mempengaruhi kesegaran dan kualitasnya.

Brokoli, sebagai contoh, dikenal sebagai sayuran yang kaya akan berbagai zat bergizi dan memiliki karakteristik morfologi yang unik [2]. Batang yang tegak dan daun yang bergerigi menjadi ciri khasnya, sementara bunga yang padat menandakan tingkat kematangan dan kesegarannya [3]. Di sisi lain, wortel, dengan umbinya yang kaya akan vitamin A memiliki siklus hidup yang berbeda dan memerlukan perawatan yang berbeda pula agar tetap segar [4]. Sedangkan bawang merah, dengan umbi yang menjadi fokus utamanya, memiliki peran penting dalam memperkaya cita rasa masakan Indonesia [5].

Pada penelitian [6] pengklasifikasian sayur sawi menggunakan metode K-*Nearest Neighbor* diperoleh accuracy sebesar 92,75% pada k=1, sedangkan pada k=3 diperoleh accuracy sebesar 90%. Selain itu pada penelitian [7] dengan penggunaan fitur ekstraksi tekstur LBP dan fitur ekstraksi warna HSV metode algoritma Support Vector Machine menghasilkan nilai accuracy tertinggi sebesar 65,02% pada nilai γ =0,04. Sementara pada penelitian [8] memisahkan antara buah dan sayuran yang segar dengan busuk menggunakan *Convolutional Neural Network* (CNN). Dalam penelitian ini, klasifikasi dengan CNN memperoleh *accuracy* pelatihan sebesar 90,42%, *accuracy* validasi mencapai 94,21%, dan *accuracy* pengujian mencapai 80,83%.

Berdasarkan penelitian sebelumnya, Penelitian ini akan melakukan klasifikasi jenis sayuran brokoli, wortel, dan bawang merah menggunakan algoritma K-NN, SVM, *Decision Tree*, dan MLP. Klasifikasi ini bertujuan untuk menguji pengenalan objek dengan input gambar melalui folder yang berisi seluruh gambar objek. Citra sayur brokoli, wortel, dan bawang merah yang digunakan akan dibagi menjadi 2 kelas, yaitu sayur segar dan sayur tidak segar.

2. METODA

Penelitian ini menggunakan metode berupa perancangan perangkat lunak dan pengujian model klasifikasi untuk mendeteksi kesegaran sayur. Proses metodologi yang diterapkan pada penelitian ini bisa diamati di Gambar 1.

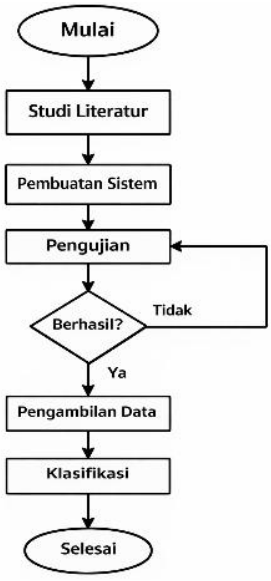

Gambar 1. Diagram alir metodologi penelitian.

Diagram alir penelitian dimulai dari studi literatur untuk mengkaji teori dan metode yang relevan. Selanjutnya dilakukan pembuatan sistem dan pengujian awal. Jika sistem belum berhasil, dilakukan perbaikan hingga sistem berjalan sesuai harapan. Setelah sistem valid, dilanjutkan dengan pengambilan data citra sayuran yang diklasifikasikan menjadi dua kategori, yaitu segar dan tidak segar. Hasil klasifikasi kemudian dievaluasi menggunakan metrik akurasi, *precision*, *recall*, dan F1-*score*.

2.1. Perancangan Perangkat Lunak

Untuk perangkat lunak, program dikembangkan menggunakan *software Jupyter*, yang merupakan salah satu lingkungan pemrograman interaktif berbasis notebook dan banyak digunakan dalam pengolahan data serta pengembangan model kecerdasan buatan [9]. Berikut adalah diagram alir perangkat lunak yang dapat dilihat pada Gambar 2, yang menggambarkan alur proses dari tahapan input data hingga klasifikasi hasil.

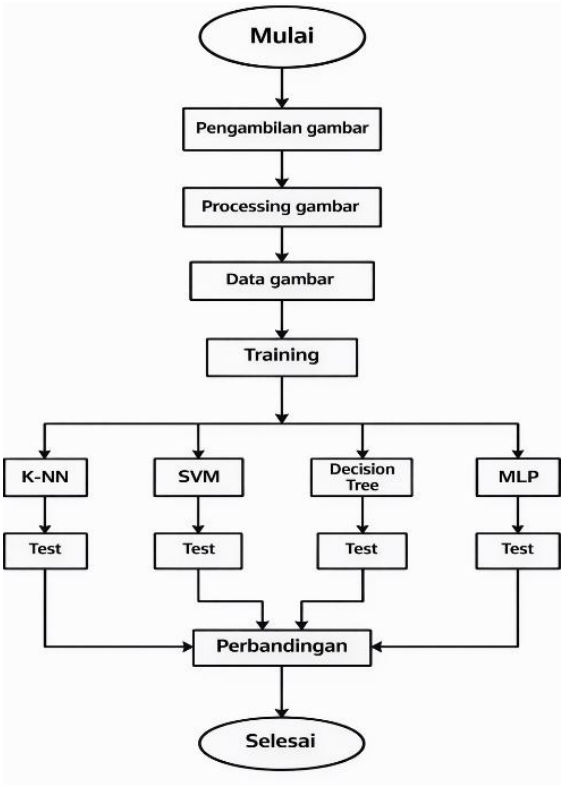

Gambar 2. Diagram alir perangkat lunak.

Dalam perancangan perangkat lunak ini, tahap pertama dimulai dengan pengambilan gambar dari folder yang berisi seluruh objek gambar. Setelah itu, dilakukan preprocessing pada gambar-gambar tersebut, kemudian diperoleh dataset gambar untuk digunakan dalam proses training model menggunakan algoritma K-NN, SVM, Decision Tree, dan MLP. Selanjutnya, dilakukan pengujian pada setiap algoritma serta perbandingan evaluasi model untuk memperoleh nilai *accuracy*, *precision*, *recall*, dan F1-score. Hasil implementasi digunakan untuk mendeteksi kesegaran sayur berdasarkan dataset gambar yang dimasukkan.

2.2. Perancangan Antarmuka Pengguna Grafis

Antarmuka pengguna grafis dirancang untuk memfasilitasi pengguna dalam melakukan pemilihan metode klasifikasi dan menjalankan proses prediksi terhadap citra sayuran. Perancangan antarmuka ini bertujuan untuk meningkatkan kemudahan operasional serta fleksibilitas dalam pengujian berbagai algoritma klasifikasi yang digunakan dalam penelitian [10]. Berikut ini ditampilkan rancangan antarmuka pengguna yang dapat dilihat pada Gambar 3.

Gambar. 3 Tampilan antarmuka pengguna grafis sistem klasifikasi.

Tampilan awal antarmuka pengguna grafis yang terdiri dari menu *dropdown* untuk memilih metode klasifikasi yaitu KNN, SVM, *Decision Tree*, dan MLP, serta tombol fungsi untuk memilih folder berisi dataset gambar dan menjalankan proses prediksi.

2.3. Preprocessing Data

Dalam melakukan *preprocessing* data, ada beberapa tahapan perancangan. Perancangan *preprocessing* data dapat dilihat pada Gambar 4.

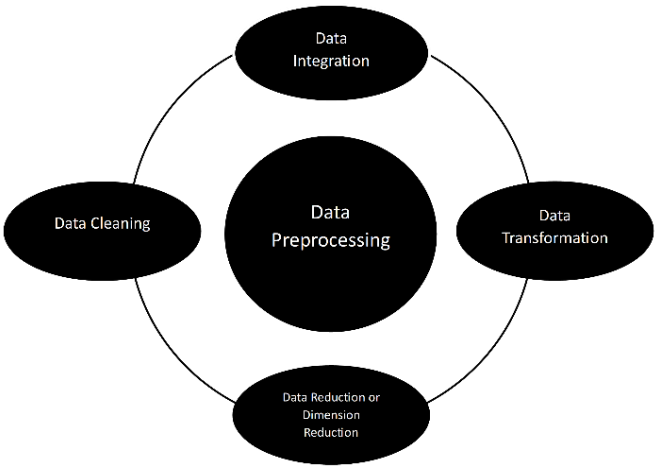

Gambar 4. Alur proses preprocessing.

Pada penelitian ini hanya data *transformation* yang digunakan pada tahap *preprocessing*. Transformasi data ini bertujuan untuk mengubah data gambar mentah menjadi representasi numerik yang sesuai untuk model klasifikasi [11]. Tahapan yang dilakukan meliputi:

1. mengatur ukuran gambar menjadi dimensi standar (64x64 piksel) agar konsisten dan siap digunakan sebagai masukan model [12].
2. mengekstrasi fitur dengan meratakan (*flattening*) setiap gambar menjadi vektor satu dimensi berbasis intensitas piksel [13].
3. menormalkan data menggunakan *StandardScaler* untuk memperoleh distribusi nilai yang seimbang, sehingga dapat meningkatkan performa model [14].

2.4. Klasifikasi Data

Setiap metode klasifikasi memiliki langkah-langkah tersendiri yang harus dilakukan secara sistematis untuk memperoleh hasil prediksi yang akurat. Klasifikasi data dalam konteks penelitian ini merujuk pada proses perancangan dan penerapan empat metode klasifikasi, yaitu *K-Nearest Neighbors*, *Support Vector Machine*, *Decision Tree*, dan *Multi-Layer Perceptron.* Langkah awal

dari proses klasifikasi adalah melakukan *preprocessing* data dilakukan dua tahapan utama yaitu *resizing image* dan *flattening* menjadi array satu dimensi. Hasil dari *preprocessing* data tersebut kemudian digunakan sebagai *input* bagi masing-masing algoritma. Pada metode K-NN, Menentukan nilai *k* dan menghitung jarak terdekat antar data [15]. Sementara itu, SVM memanfaatkan *hyperplane* dengan *kernel* tertentu untuk *multiclass classification* [16]. Metode *Decision Tree* membentuk struktur pohon berdasarkan nilai atribut tertentu untuk mengambil keputusan klasifikasi [17]. Adapun MLP, sebagai bagian dari jaringan saraf tiruan, memanfaatkan proses pelatihan berlapis (*layered learning*) dengan bobot dan fungsi aktivasi untuk mengenali pola pada data [18].

2.5. Pengujian dan Evaluasi

Pengujian dilakukan pada data uji untuk mengukur performa setiap model klasifikasi menggunakan *confusion matrix* dan *classification report*. Parameter evaluasi yang digunakan meliputi nilai *accuracy*, *precision*, *recall*, dan *F1-score* [19]. Keempat metrik ini memberikan gambaran menyeluruh terhadap kemampuan model dalam membedakan antara sayur segar dan tidak segar. Hasil pengujian dari masing-masing metode kemudian dibandingkan untuk menentukan metode yang paling efektif dan optimal dalam mengklasifikasikan kualitas kesegaran sayur.

3. HASIL DAN PEMBAHASAN

3.1 Pengumpulan Dataset

Pengumpulan dataset dilakukan dengan membuat folder yang terdiri dari dua subfolder utama, yaitu data latih dan data uji. Masing-masing subfolder tersebut berisi gambar-gambar yang telah dikelompokkan berdasarkan kelas sayuran, yaitu sayuran segar dan tidak segar. Struktur ini memudahkan proses pemanggilan dan pemisahan data saat pelatihan dan pengujian model klasifikasi.

Folder data latih berisi 480 gambar untuk klasifikasi kesegaran sayuran, terdiri dari tiga jenis: brokoli, bawang merah, dan wortel, masing-masing dalam dua kategori, yaitu segar dan tidak segar. Dataset disusun secara terorganisir, dengan nama file merepresentasikan jenis dan kondisi sayuran. Gambar diambil dari berbagai sudut dan pencahayaan untuk meningkatkan generalisasi model. Jumlah data tiap kategori seimbang guna menghindari bias, serta struktur folder yang rapi mendukung efisiensi dalam pelabelan, ekstraksi fitur, dan evaluasi model [20].

Sedangkan folder data uji yang berisi 120 gambar dataset untuk klasifikasi kesegaran sayuran, terdiri dari brokoli, bawang merah, dan wortel dalam dua kategori: segar dan tidak segar. Data uji digunakan untuk mengevaluasi kinerja model yang telah dilatih, dengan gambar-gambar bervariasi dalam pencahayaan, posisi, dan sudut pandang untuk menguji kemampuan generalisasi model [21]. Setiap kelas berisi 20 gambar, dengan distribusi seimbang guna menghindari bias evaluasi. Struktur dataset ini penting untuk menjaga integritas proses pengujian dan mengukur *accuracy*, *precision*, *recall*, serta *F1-score* model.

3.2 Preprocessing Data

Untuk *preprocessing* data, dilakukan dua tahapan utama yaitu *resizing image* dan *flattening* menjadi array satu dimensi. *Resizing* bertujuan untuk menyamakan dimensi seluruh gambar agar sesuai dengan *input* model, sedangkan *flattening* mengubah gambar menjadi vektor numerik yang merepresentasikan intensitas piksel. Berikut tampilan hasil *preprocessing* data dapat dilihat pada Tabel 1.

Tabel 1. Hasil resizing image dan array hasil flatten.

Sayuran	Kelas	Hasil *Resizing*	Array Hasil *Flatten*
Brokoli	Segar		**[95 100 101 … 218 225 222]**
	Tidak Segar		**[191 173 176 … 149 155 196]**
Wortel	Segar		**[[129 130 128 … 114 123 127]**
	Tidak Segar		**[89 72 44 … 123 131 124]**
Bawang Merah	Segar		**[184 181 176 … 175 17 170]**
	Tidak Segar		**[180 183 188 … 196 199 203]**

Hasil *preprocessing* gambar sayuran yang diklasifikasikan sebagai "segar" dan "tidak segar". Proses dimulai dengan *resizing* gambar menjadi 64x64 piksel untuk memastikan dimensi seragam, lalu dilakukan *flattening* agar gambar menjadi array satu dimensi. Setiap nilai dalam array mewakili intensitas piksel (0–255), mencerminkan tingkat kecerahan atau warna. Brokoli segar menunjukkan pola intensitas khas dengan warna hijau cerah, sedangkan brokoli tidak segar memiliki intensitas lebih gelap karena perubahan warna. Wortel segar menampilkan warna oranye terang, berbeda dengan wortel tidak segar yang lebih kusam. Bawang merah segar memiliki intensitas merata dan cerah, sementara yang tidak segar menunjukkan warna gelap atau bintik kecoklatan akibat pembusukan. Contoh *array* [95 100 101 … 218 225 222] menunjukkan variasi intensitas dari area gelap (bayangan/hijau tua) hingga terang (area terkena cahaya).

3.3 Memisahkan Data Parameter dan Kelas

Pada tahap ini, data latih dan data uji masing-masing dipisahkan menjadi dua bagian, yaitu data parameter (fitur) dan data kelas (label). Data parameter berupa nilai numerik hasil *flattening* dari gambar, sedangkan data kelas berisi informasi kategori seperti sayuran segar atau tidak segar.

3.3.1. Data Latih

Untuk memisahkan data parameter dan kelas dibagi menjadi dua yaitu data latih dan data uji. Berikut tampilan gambar sayur pada data latih dapat dilihat pada Gambar 5.

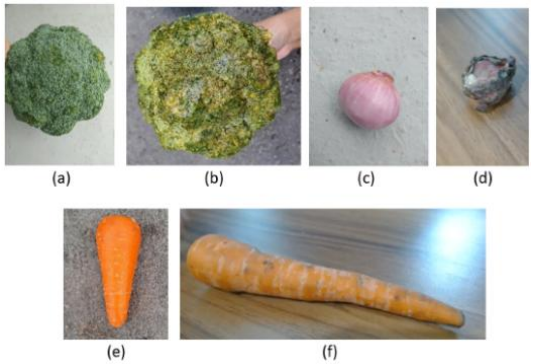

Gambar 5. Gambar sayur setiap kelas pada data latih.

Dataset data latih terdiri dari enam kategori, yaitu brokoli segar, brokoli tidak segar, bawang merah segar, bawang merah tidak segar, wortel segar, dan wortel tidak segar, masing-masing berjumlah 80 gambar dengan total 480 gambar. Distribusi yang seimbang ini memastikan model belajar tanpa bias terhadap salah satu kelas [22]. Setiap gambar mewakili ciri khas visual, seperti brokoli segar dengan warna hijau cerah dan struktur rapat, brokoli tidak segar yang kusam dan rusak, bawang merah segar dengan kulit halus dan warna cerah, serta bawang merah tidak segar yang memiliki tekstur rusak dan warna gelap. Wortel segar tampak oranye cerah dan halus, sementara wortel tidak segar menunjukkan warna pudar dan kerusakan. Pendekatan ini bertujuan meningkatkan *accuracy* model dalam mengenali kesegaran sayuran berdasarkan ciri visual.

3.3.2. Data Uji

Untuk memisahkan data parameter dan kelas dibagi menjadi dua yaitu data latih dan data uji. Berikut tampilan gambar sayur pada data uji dapa dilihat pada Gambar 6.

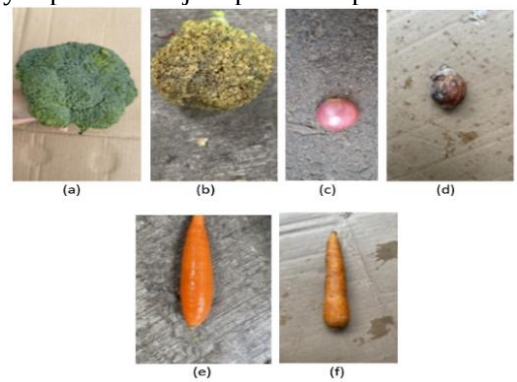

Gambar 6. Gambar sayur setiap kelas pada data uji.

Dataset uji yang terdiri dari 120 gambar tiga jenis sayuran (brokoli, bawang merah, dan wortel), masing-masing terbagi dalam kategori segar dan tidak segar sebanyak 20 gambar per kelas. Brokoli segar berwarna hijau cerah, sedangkan yang tidak segar kecokelatan atau layu. Bawang merah segar memiliki kulit merah cerah, sementara yang tidak segar tampak kusam dan membusuk. Wortel segar berwarna oranye cerah dan halus, sedangkan yang tidak segar kusam dan keriput. Dataset ini digunakan untuk menguji kemampuan model dalam mengklasifikasikan kesegaran berdasarkan warna, tekstur, dan bentuk, dengan variasi pencahayaan dan sudut gambar untuk mengukur generalisasi model *melalui accuracy, precision, recall,* dan *F1-score* [23].

3.4 Hasil Klasifikasi K-NN

Pada tahap klasifikasi menggunakan metode *K-Nearest Neighbors* didapat hasil yang menjadi keluaran klasifikasi, yaitu: *confusion matrix*, dan *classification report*. Dapat dilihat pada Gambar 7 dan 8. Berdasarkan *confusion matrix*, model menunjukkan performa baik pada brokoli dan bawang merah tidak segar, dengan masing-masing 16 dan 20 prediksi benar tanpa kesalahan. Namun, performa menurun pada wortel segar (11 benar, 5 salah sebagai tidak segar) dan brokoli segar (4 salah klasifikasi). Bawang merah segar juga menunjukkan kesalahan signifikan, dengan hanya 10 prediksi benar dan 9 salah sebagai tidak segar. Hal ini menunjukkan kesulitan model membedakan fitur visual yang mirip serta kemungkinan adanya bias [24].

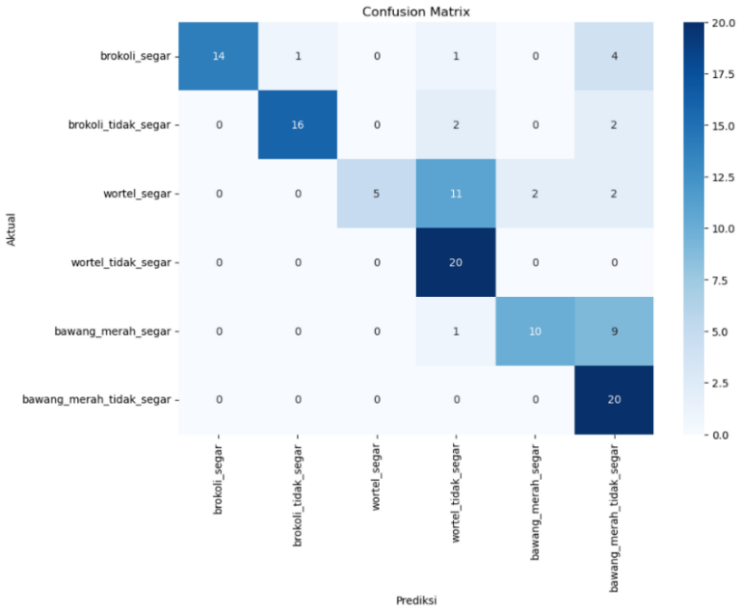

Gambar 7. *Confusion matrix* K-NN.

Classification Report:

	precision	recall	f1-score	support
brokoli_segar	1.00	0.70	0.82	20
brokoli_tidak_segar	0.94	0.80	0.86	20
wortel_segar	1.00	0.25	0.40	20
wortel_tidak_segar	0.57	1.00	0.73	20
bawang_merah_segar	0.83	0.50	0.62	20
bawang_merah_tidak_segar	0.54	1.00	0.70	20
accuracy			0.71	120
macro avg	0.81	0.71	0.69	120
weighted avg	0.81	0.71	0.69	120

Gambar 8. *Classification report* K-NN.

Hasil klasifikasi menunjukkan *accuracy* 71%, dengan *precision* dan *recall* identik (0.81 dan 0.71), menandakan performa konsisten antar kelas. Brokoli segar memiliki *precision* sempurna namun *recall* 0.70, menunjukkan model akurat tapi masih melewatkan sebagian data. Brokoli tidak segar mencatat performa terbaik (*F1-score* 0.86), sedangkan wortel segar memiliki *precision* tinggi namun *recall* rendah (0.25), menghasilkan *F1-score* 0.40. Dengan 20 sampel per kelas, variasi performa disebabkan oleh kompleksitas fitur, bukan ketidakseimbangan data.

3.5 Hasil Klasifikasi SVM

Pada tahap klasifikasi menggunakan metode SVM didapat hasil yang menjadi keluaran klasifikasi, yaitu: *confusion matrix*, dan *classification report* (lihat Gambar 9 dan Gambar 10). Berdasarkan *confusion matrix*, model SVM tampil sangat baik pada wortel dan bawang merah tidak segar dengan 20 TP tanpa kesalahan. Namun, performa menurun pada wortel segar (5 salah klasifikasi) dan bawang merah segar (8 kesalahan, termasuk 2 salah ke tidak segar). Brokoli segar juga mengalami beberapa kesalahan klasifikasi, sementara brokoli tidak segar mencatat 19 TP dan 1 FP. Kesalahan disebabkan kemiripan visual antar kelas, *noise*, kualitas data, serta *preprocessing* yang kurang optimal. Perbaikan dapat dilakukan melalui *augmentasi* data, ekstraksi fitur lanjutan (misalnya *transfer learning*), dan optimasi *hyperparameter*.

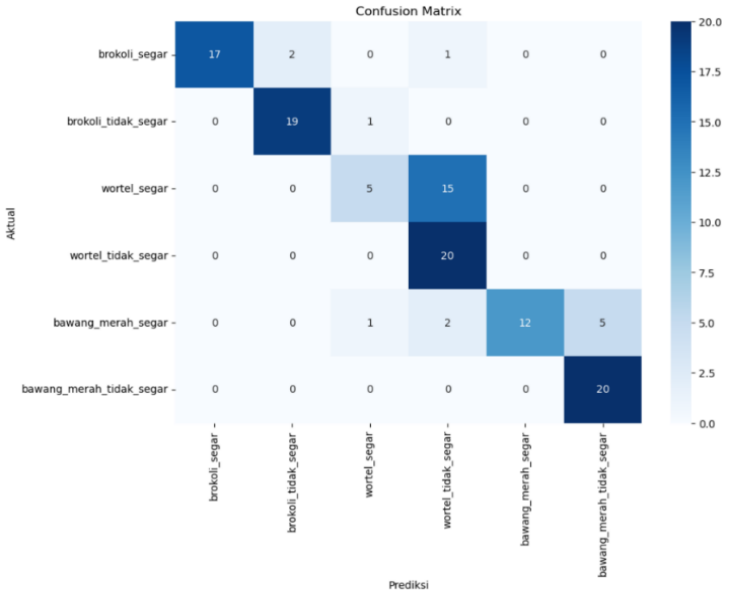

Gambar 9. *Confusion matrix* SVM.

Classification Report:

	precision	recall	f1-score	support
brokoli_segar	1.00	0.85	0.92	20
brokoli_tidak_segar	0.90	0.95	0.93	20
wortel_segar	0.71	0.25	0.37	20
wortel_tidak_segar	0.53	1.00	0.69	20
bawang_merah_segar	1.00	0.60	0.75	20
bawang_merah_tidak_segar	0.80	1.00	0.89	20
accuracy			0.78	120
macro avg	0.82	0.78	0.76	120
weighted avg	0.82	0.78	0.76	120

Gambar 10. *Confusion report* SVM.

Hasil *classification report* SVM menunjukkan *accuracy* 78% dengan performa bervariasi antar kelas. Brokoli segar memiliki *precision* 1.00, *recall* 0.85, dan *F1-score* 0.92, sementara wortel segar menunjukkan performa rendah *F1-score* 0.37 akibat *recall* yang hanya 0.25. Wortel tidak segar memiliki *recall* sempurna namun *precision* rendah yaitu 0.53, menunjukkan banyak kesalahan klasifikasi dari kelas lain. Bawang merah segar memiliki *precision* 1.00, dan *recall* 0.60. Performa terbaik ditunjukkan oleh brokoli dan bawang merah tidak segar. Secara keseluruhan, model cukup baik namun masih perlu perbaikan, terutama pada kelas wortel segar.

3.6 Hasil Klasifikasi *Decision Tree*

Gambar 11. menunjukkan *plot Decision Tree* dengan *max depth* 3, terdiri dari 3 *internal node* dan 7 *terminal node*. *Root node* memakai fitur 4499 (≤ 1.251), gini 0.833, dan 480 sampel, menandakan perlu pemisahan lanjutan. Cabang *true* menggunakan fitur 3795 (gini 0.812, 408 sampel), sedangkan cabang *false* memakai fitur 10598 (gini 0.156, 72 sampel) yang didominasi wortel segar. Salah satu terminal node memiliki gini 0 dengan 4 sampel wortel tidak segar, menunjukkan klasifikasi sempurna.

Pada tahap klasifikasi menggunakan metode *Decision Tree* didapat hasil yang menjadi keluaran klasifikasi, yaitu: *plot Decision Tree*, *confusion matrix*, dan *classification report*. Dimana *confusion matrix* terlihat pada Gambar 12, sedangkan *classification report* pada Gambar 13.

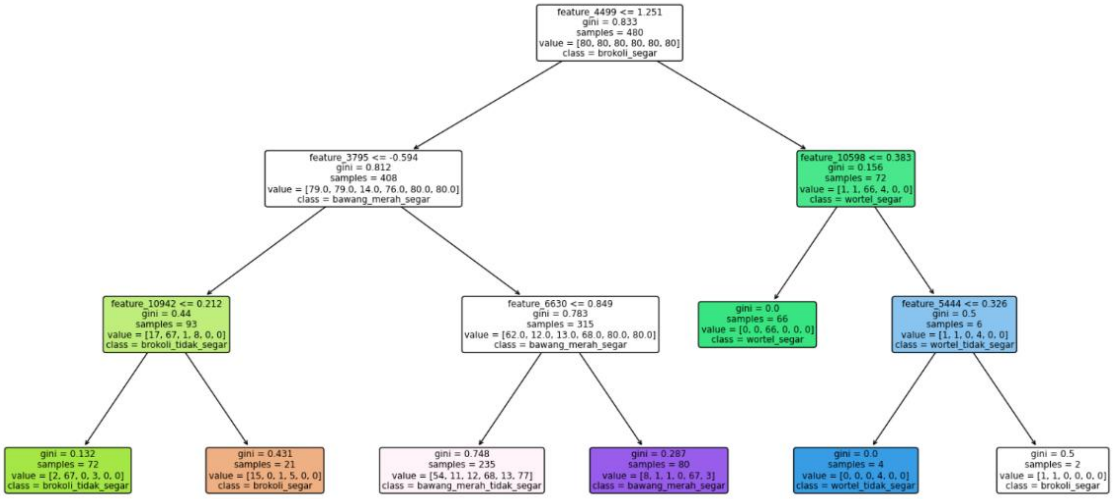

Gambar 11. *Plot Decision Tree*.

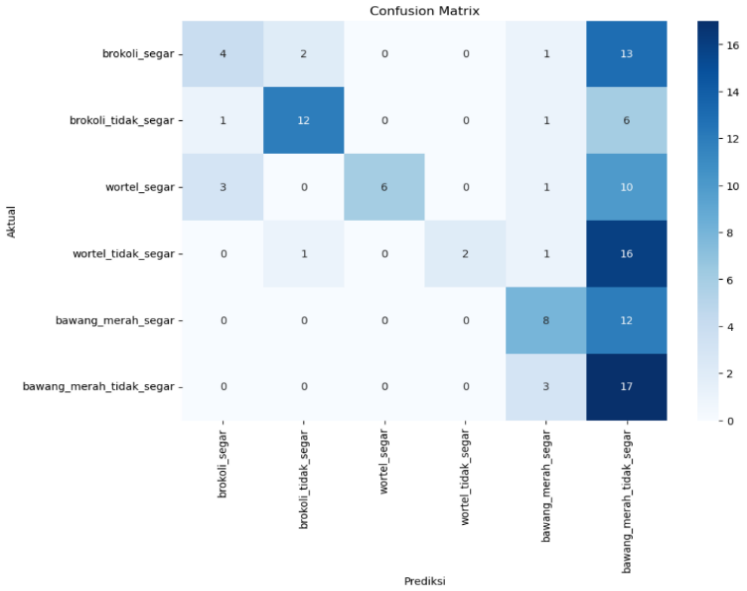

Gambar 12. *Confusion matrix Decision Tree*.

Classification Report:

	precision	recall	f1-score	support
brokoli_segar	0.50	0.20	0.29	20
brokoli_tidak_segar	0.80	0.60	0.69	20
wortel_segar	1.00	0.30	0.46	20
wortel_tidak_segar	1.00	0.10	0.18	20
bawang_merah_segar	0.53	0.40	0.46	20
bawang_merah_tidak_segar	0.23	0.85	0.36	20
accuracy			0.41	120
macro avg	0.68	0.41	0.41	120
weighted avg	0.68	0.41	0.41	120

Gambar 13. *Classification report Decision Tree.*

Berdasarkan *confusion matrix*, performa model bervariasi per kelas. Brokoli segar hanya 4 dari 20 diklasifikasi benar, dengan 13 salah ke bawang merah tidak segar. Brokoli tidak segar memiliki 12 prediksi benar, tapi 4 salah ke wortel tidak segar. Wortel segar hanya 6 benar, sementara wortel tidak segar cukup baik dengan 16 benar. Bawang merah segar hanya 8 benar,

sedangkan bawang merah tidak segar terbaik dengan 17 benar. Model cenderung bias ke bawang merah tidak segar dan kesulitan membedakan fitur visual serupa. Performa dapat ditingkatkan dengan menambah data latih, optimasi fitur, atau model yang lebih kompleks [25].

Hasil klasifikasi menunjukkan *accuracy* rendah senilai 41%, menandakan model kesulitan mengklasifikasikan kesegaran sayuran. Meskipun distribusi data seimbang dengan nilai *precision* dan *recall* 0.68 dan 0.41, performa tetap buruk. Wortel segar dan tidak segar memiliki *precision* sempurna, tapi *recall* sangat rendah yaitu 0.30 dan 0.10, menghasilkan *F1-score* rendah. Brokoli tidak segar tampil lebih baik dengan nilai *F1-score* 0.69 dibanding brokoli segar 0.29. Bawang merah tidak segar memiliki *recall* tinggi 0.85, tetapi *precision* rendah 0.23, menunjukkan banyak *false positives*. Performa buruk disebabkan ketidakmampuan model mengenali fitur penting, bukan ketidakseimbangan data.

3.7 Hasil Klasifikasi MLP

Pada tahap klasifikasi menggunakan metode MLP didapat hasil yang menjadi keluaran klasifikasi, yaitu: *confusion matrix*, dan *classification report*. Gambar 14 dan 15 memperlihatkan hasil dari *confusion matrix* dan *classification report* dari metoda ini.

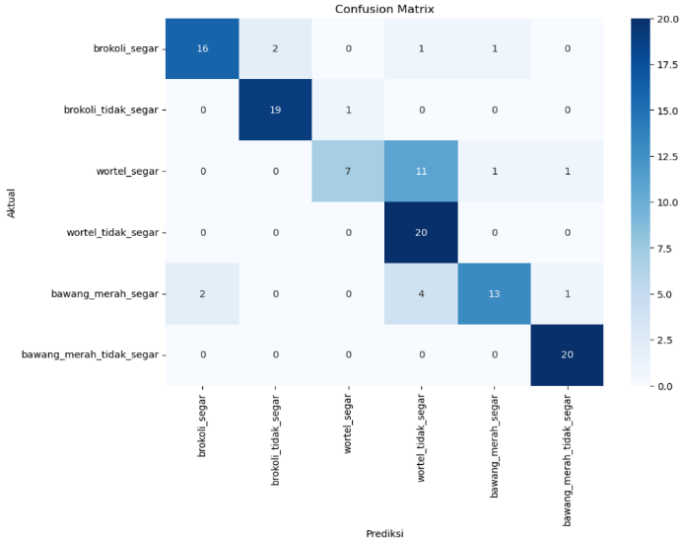

Gambar 14. *Confusion matrix* MLP.

Berdasarkan Gambar 14. *confusion matrix*, model MLP menunjukkan hasil sangat baik pada wortel dan bawang merah tidak segar (20 TP tanpa kesalahan). Namun, wortel segar hanya 7 TP dan 11 salah, sebagian besar ke wortel tidak segar akibat kemiripan visual. Bawang merah segar juga keliru, 4 salah ke brokoli segar dan 1 ke bawang merah tidak segar. Brokoli segar menunjukkan kesalahan serupa, kemungkinan karena fitur antar kelas tumpang tindih atau kurangnya variasi data latih.

Classification Report:

	precision	recall	f1-score	support
brokoli_segar	0.89	0.80	0.84	20
brokoli_tidak_segar	0.90	0.95	0.93	20
wortel_segar	0.88	0.35	0.50	20
wortel_tidak_segar	0.56	1.00	0.71	20
bawang_merah_segar	0.87	0.65	0.74	20
bawang_merah_tidak_segar	0.91	1.00	0.95	20
accuracy			0.79	120
macro avg	0.83	0.79	0.78	120
weighted avg	0.83	0.79	0.78	120

Gambar 15. *Classification report* MLP.

Berdasarkan *classification report* MLP, nilai *accuracy* 79% dengan performa terbaik pada brokoli dan bawang merah tidak segar (*precision* >0.90, *recall* ≥0.95). Wortel segar memiliki *precision* tinggi (0.88) namun *recall* rendah (0.35), menunjukkan banyak salah klasifikasi. Wortel tidak segar memiliki *recall* sempurna (1.00) tetapi nilai *precision* rendah (0.56), menandakan banyak *false positive*. Bawang merah segar mencatat *precision* 0.87 dan *recall* 0.65. Secara keseluruhan, *F1-score* makro 0.78 menunjukkan performa cukup baik, meski masih perlu perbaikan di beberapa kelas.

3.8 Data Pengujian

Setelah pengujian, diperoleh data gambar sayuran segar dan tidak segar (bawang merah, brokoli, dan wortel) yang diklasifikasikan menggunakan metode K-NN, SVM, *Decision Tree*, dan MLP. Pengujian bertujuan menilai performa alat dalam mendeteksi kesegaran sayuran berdasarkan metrik *accuracy*, *precision*, *recall*, dan *F1-score.*

3.8.1. Data Pengujian

Pengujian menggunakan tiga jenis sayuran (bawang merah, brokoli, dan wortel) dalam dua kategori: segar dan tidak segar. Data uji berupa gambar yang telah diklasifikasikan, dengan rincian jumlah dan distribusi ditampilkan pada Tabel 2.

Tabel 2. Rincian data pengujian.

Sayuran	Kelas	Jumlah	Total
Bawang Merah	Segar	20	**40**
	Tidak Segar	20	
Brokoli	Segar	20	**40**
	Tidak Segar	20	
Wortel	Segar	20	**40**
	Tidak Segar	20	

Data uji terdiri dari tiga jenis sayuran: bawang merah, brokoli, dan wortel, masing-masing dengan 20 sampel segar dan 20 tidak segar. Distribusi seimbang ini bertujuan menghindari bias dan memastikan model belajar secara efektif.

3.8.2. Hasil Pengujian Dasar

Hasil pengujian menunjukkan kinerja beberapa metode klasifikasi dalam mendeteksi kesegaran sayuran, dievaluasi menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score* Terlihat pada Tabel 3.

Tabel 3. Hasil pengujian klasifikasi kesegaran sayuran.

No	Metode Klasifikasi	Accuracy	Precision	Recall	F1-score
1	K-NN	70.83%	81.44%	70.83%	**69.04%**
2	SVM	77.50%	82.42%	77.50%	**75.74%**
3	Decision Tree	40.83%	67.72%	40.83%	**40.56%**
4	MLP	79.17%	83.33%	79.17%	**77.97%**

MLP menunjukkan performa terbaik dengan *accuracy* 79.17%, *precision* 83.33%, *recall* 79.17%, *F1-score* 77.97% karena kemampuannya menangkap pola kompleks. SVM menghasilkan performa yang baik dengan akurasi sebesar 77,50% dan F1-score sebesar 75,74%, sehingga cocok digunakan untuk data yang memiliki margin kelas yang jelas. Metode K-NN menunjukkan performa yang cukup baik dengan *accuracy* sebesar 70,83% dan *F1-score* sebesar 69,04%, namun

kinerjanya sensitif terhadap pemilihan nilai k serta distribusi data. *Decision Tree* memiliki performa terendah dengan nilai *accuracy* 40.83%, *F1-score* 40.6%, hal ini dikarenakan *overfitting* dan struktur model yang kurang kompleks.

3.8.3. Pengujian *Hyperparameter*

Pengujian *hyperparameter* dilakukan untuk mengoptimalkan kinerja model dengan menyesuaikan parameter tertentu guna meningkatkan *accuracy* dan efektivitas klasifikasi kesegaran sayuran. Nilai-nilainya ditampilkan pada Tabel 4.

Tabel 4. Parameter *hyperparameter tuning*.

Metode Klasifikasi	Parameter yang diubah	Nilai Optimal
K-NN	Jumlah Tetangga (K)	**3**
SVM	Kernel	**Linear**
Decision Tree	Max Depth	**3**
MLP	Hidden Layer Sizes	**128, 64**

Berdasarkan Tabel 4, pengujian *hyperparameter* dilakukan untuk mengoptimalkan performa model. Pada K-NN, nilai *k* optimal adalah 3 untuk menghindari prediksi imbang. SVM bekerja paling baik dengan kernel linear, menunjukkan pemisahan antar kelas cukup linier. *Decision Tree* optimal pada *max depth* 3 untuk mencegah *overfitting*. MLP mencapai performa terbaik dengan konfigurasi *hidden layer* 128 dan 64, memungkinkan model mengenali pola kompleks. Pemilihan *hyperparameter* yang tepat terbukti meningkatkan kinerja klasifikasi.

3.9 Evaluasi Hasil Pengujian

Pada bagian ini dilakukan analisis terhadap hasil pengujian metode klasifikasi dalam mendeteksi kesegaran bawang merah, brokoli, dan wortel. Evaluasi menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix* untuk menentukan metode paling efektif dalam membedakan sayur segar dan tidak segar.

3.9.1. Analisis Kesalahan Klasifikasi

Kesalahan klasifikasi disebabkan oleh kualitas gambar rendah, pencahayaan tidak konsisten, dan kemiripan fitur antar kategori. Rincian kesalahan ditampilkan pada Tabel 5.

Tabel 5. Kesalahan klasifikasi (*error analysis*).

Sayuran	Metode Klasifikasi	Kesalahan Prediksi (segar)	Kesalahan Prediksi (tidak segar)	Total Kesalahan	% Error
Bawang Merah	K-NN	-	10	10	**25%**
	SVM	8	-	8	**20%**
	Decision Tree	12	3	15	**37.5%**
	MLP	7	-	7	**17.5%**
Brokoli	K-NN	6	4	10	**25%**
	SVM	3	1	4	**10%**
	Decision Tree	16	8	24	**60%**
	MLP	4	1	5	**12.5**
Wortel	K-NN	9	-	9	**22.5%**
	SVM	15	-	15	**37.5%**
	Decision Tree	14	18	32	**80%**
	MLP	13	-	13	**32.5%**
Rata-Rata Error					**31.67%**

Klasifikasi menggunakan K-NN, SVM, *Decision Tree*, dan MLP pada tiga jenis sayuran menunjukkan bahwa MLP memiliki rata-rata *error* terendah, terutama pada bawang merah (17,5%) dan brokoli (12,5%). Sebaliknya, *Decision Tree* mencatat *error* tertinggi, terutama pada

wortel (80%). Rata-rata *error* keseluruhan adalah 31,67%, menandakan MLP sebagai metode paling efektif dalam mengklasifikasikan kesegaran sayuran.
Berikut perhitungan *%Error* dengan menggunakan rumus:

$$\%\ Error = \frac{total\ kesalahan}{total\ data\ uji\ per\ sayur} \times 100 \quad (1)$$

3.10 Perbandingan Performansi dari Metode Klasifikasi

Setelah diperoleh nilai *accuracy*, *precision*, *recall*, dan *F1-score*, dilakukan perbandingan performa untuk mengevaluasi efektivitas masing-masing metode dalam mendeteksi kesegaran sayuran. Hasil perbandingan ditampilkan pada Gambar 16.

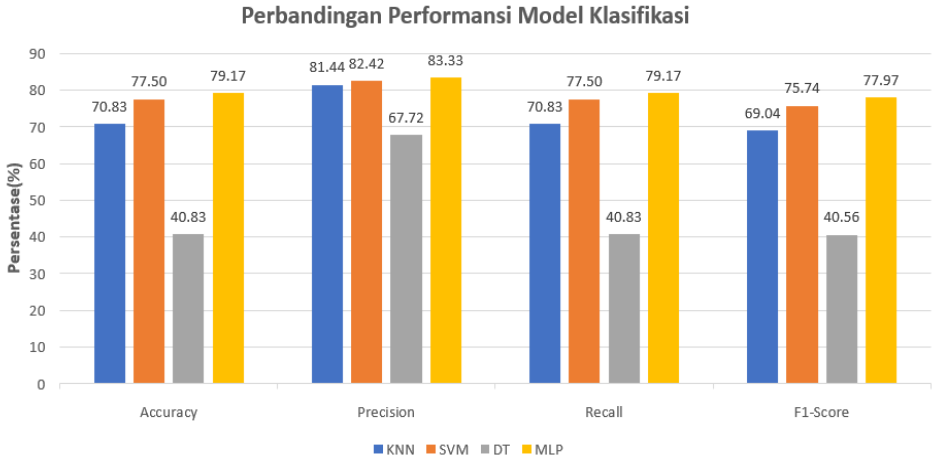

Gambar 16. Perbandingan performansi metode klasifikasi.

Diagram menunjukkan perbandingan performa KNN, SVM, *Decision Tree*, dan MLP berdasarkan metrik *macro average*. MLP unggul di semua metrik dengan nilai *accuracy* 79.17%, dan *F1-score* 77.97%, diikuti SVM dengan nilai *accuracy* 77.50%, dan *F1-score* 75.74% dan KNN dengan *accuracy* 70.83%, dan *F1-score* 69.04%. *Decision Tree* menunjukkan performa terendah dengan nilai *accuracy* dan *recall* 40.83%, *F1-score* 40.56%. MLP menjadi model terbaik, disusul SVM dan KNN, sedangkan *Decision Tree* paling lemah.

4. KESIMPULAN

Penelitian ini menunjukkan bahwa klasifikasi kesegaran sayuran berbasis citra digital dapat dilakukan secara efektif menggunakan pendekatan pembelajaran mesin. Empat metode klasifikasi, yaitu K-NN, SVM, Decision Tree, dan MLP, telah dibandingkan dalam mengklasifikasikan tiga jenis sayuran ke dalam kategori segar dan tidak segar. Hasil pengujian menunjukkan bahwa metode MLP memberikan kinerja paling optimal dibandingkan metode lainnya karena mampu menangkap pola visual yang lebih kompleks pada data citra. Metode SVM dan K-NN juga menunjukkan performa yang cukup baik, sementara Decision Tree memiliki keterbatasan dalam membedakan karakteristik visual antar kelas. Secara keseluruhan, hasil penelitian ini menegaskan potensi penerapan metode pembelajaran mesin, khususnya MLP, sebagai dasar pengembangan sistem klasifikasi kesegaran sayuran yang lebih andal dan aplikatif di masa mendatang.

KONFLIK KEPENTINGAN

Para penulis menyatakan tidak ada konflik kepentingan.

Referensi

[1] A. M. Smith and A. L. Collene, Contempory Nutrition. New York, N.Y. : Mc Graw-Hill Education, 2016.

[2] E. Whitney and S. R. Rolfes, Understanding Nutrition. Cengage Learning, 2019.

[3] O. A. Elshehaby, W. M. Shukry, M. Abdallah, A. M. Gabber, and D. A. Galilah, "Morphological Criteria and Carbohydrates Content of Broccoli (Brassica oleracea L var Italica) Affected by Different Levels of Sulfur Fertilizers and Waste Water," pp. 73–78, 2015.

[4] D. M. Hillis, D. E. Sadava, H. C. Heller, and S. D. Hacker, Life : The Science of Biology. Macmillan Learning, 2017.

[5] A. A. B, R. Firdaus, H. Haerudin, and F. Rokhman, Proceedings of the International Symposium Southeast Asia Vegetable 2021 (SEAVEG 2021). Atlantis Press International BV, 2023. doi: 10.2991/978-94-6463-028-2.

[6] Y. Miranti, "Klasifikasi Kesegaran Sayur Sawi Berdasarkan Citra Hsv Menggunakan Metode K-Nearest Neighbor," 2023.

[7] E. Hartati, "Penggunaan Klasifikasi Sayur Segar Dan Sayur Busuk Menggunakan Algoritma Support Vector Machine," JATISI (Jurnal Tek. Inform. dan Sist. Informasi), vol. 7, no. 3, pp. 678–687, 2020.

[8] E. A. N. Munfaati and A. Witanti, "Klasifikasi Buah dan Sayuran Segar atau Busuk Menggunakan Convolutional Neural Network," JISKA (Jurnal Inform. Sunan Kalijaga), vol. 9, no. 1, pp. 27–38, 2024, doi: 10.14421/jiska.2024.9.1.27-38.

[9] C. D. González-Carrillo, F. Restrepo-Calle, J. J. Ramírez-Echeverry, and F. A. González, "Automatic grading tool for jupyter notebooks in artificial intelligence courses," Sustain., vol. 13, no. 21, pp. 1–26, 2021, doi: 10.3390/su132112050.

[10] A. A. Rahmadi and A. Sudaryanto, "Visual Recognition Of Graphical User Interface Components Using Deep Learning Technique," J. Ilmu Komput. dan Inf., vol. 13, no. 1, pp. 35–45, 2020, doi: 10.21609/jiki.v13i1.845.

[11] A. Hassan and M. Sabha, "Feature Extraction for Image Analysis and Detection using Machine Learning Techniques," Int. J. Adv. Netw. Appl., vol. 14, no. 04, pp. 5499–5508, 2023, doi: 10.35444/ijana.2023.14401.

[12] A. H. Hoang, C. Lepenik, and M. Stahlhofen, "Two-loop massive quark jet functions in SCET," J. High Energy Phys., vol. 2019, no. 8, 2019, doi: 10.1007/JHEP08(2019)112.

[13] N. Jain, "A review of data preprocessing techniques for image classification," Comput. Sci. Rev. Elsevier, 2021.

[14] W. Luo, "Feature normalization techniques in deep learning: A survey," Inf. Fusion, Elsevier, 2022.

[15] K. P. Murphy, "Machine Learning - A Probabilistic Perspective - Table-of-Contents," MIT Press, p. 1049, 2012.

[16] C. Cortes and V. Vapnik, "Support-vector networks," Mach. Learn., 1995, doi: 10.1088/1742-6596/628/1/012073.

[17] J. R. Quinlan, "Induction of decision trees," Mach. Learn., vol. 1, no. 1, pp. 81–106, 1986, doi: 10.1007/bf00116251.

[18] I. Goodfellow, Y. Bengio, and A. Courville, Deep Learning Adaptive Computation and Machine Learning series. MIT Press, 2016.

[19] G. James, D. Witten, T. Hastie, and R. Tibshirani, An Intoduction to Statistical Learning: with Application in R. Springer Science & Business Media, 2013.

[20] J. Z. Bengar, J. Van De Weijer, L. L. Fuentes, and B. Raducanu, "Class-Balanced Active Learning for Image Classification," Proc. - 2022 IEEE/CVF Winter Conf. Appl. Comput. Vision, WACV 2022, pp. 3707–3716, 2022, doi: 10.1109/WACV51458.2022.00376.

[21] L. Murmann, M. Gharbi, M. Aittala, and F. Durand, "A dataset of multi-illumination images in the wild," Proc. IEEE Int. Conf. Comput. Vis., vol. 2019-Octob, pp. 4079–4088, 2019, doi: 10.1109/ICCV.2019.00418.

[22] Y. Suryawanshi, K. Patil, and P. Chumchu, "VegNet: Dataset of vegetable quality images for machine learning applications," Data Br., vol. 45, p. 108657, 2022, doi: 10.1016/j.dib.2022.108657.

[23] Y. Yuan and X. Chen, "Vegetable and fruit freshness detection based on deep features and principal component analysis; Vegetable and fruit freshness detection," Curr. Res. Food Sci., vol. 8, no. October 2023, p. 100656, 2024, doi: 10.1016/j.crfs.2023.100656.

[24] K. . Ting, Encyclopedia of Machine Learning. Springer, 2011.

[25] C. Sun, A. Shrivastava, S. Singh, and A. Gupta, "Revisiting Unreasonable Effectiveness of Data in Deep Learning Era," Proc. IEEE Int. Conf. Comput. Vis., vol. 2017-October, pp. 843–852, 2017, doi: 10.1109/ICCV.2017.97.