

STUDI KOMPARATIF MODEL *MACHINE LEARNING* UNTUK KLASIFIKASI WARNA RGB DAUN SELADA (*LACTUCA SATIVA L.*) HIDROPONIK TERHADAP PEMBERIAN PUPUK SILIKA SEKAM PADI

Bima Bayu Saputra¹, Ely Setyo Astuti², Ulla Delfana Rosiani³

^{1,2,3}Jurusan Teknologi Informasi, Politeknik Negeri Malang

¹bimabayus7994@gmail.com, ²ely.setyo.astuti@polinema.ac.id, ³rosiani@polinema.ac.id

Abstrak

Penelitian ini bertujuan untuk mengklasifikasikan warna daun *Lactuca sativa L.* hidroponik berdasarkan variasi dosis pupuk silika sekam padi menggunakan pendekatan machine learning. Data yang digunakan berupa nilai RGB hasil pembacaan sensor TCS34725 yang terhubung dengan Arduino Uno. Setiap data dikategorikan ke dalam empat kelas perlakuan, yaitu tanpa penyemprotan, satu kali, tiga kali, dan lima kali penyemprotan pupuk silika. Tahapan penelitian mencakup rekayasa fitur (normalisasi RGB, transformasi ke ruang warna HSV dan CIELab, serta rasio antar kanal warna seperti R/G dan G/B), seleksi fitur dengan metode kombinasi subset dan algoritma seperti PCA serta Mutual Information, pelatihan model dengan AdaBoost-SVM dan Bagging-SVM, serta evaluasi performa menggunakan Stratified K-Fold Cross-Validation (10 lipatan). Hasil menunjukkan bahwa model Bagging-SVM memberikan performa terbaik dengan akurasi uji 73,67% dan selisih train-test sebesar 3,87%, sedangkan AdaBoost-SVM memperoleh akurasi 70,90%. Dengan demikian, metode Bagging-SVM lebih stabil dan efektif dalam menangani data warna daun berbasis sensor RGB. Penelitian lanjutan direkomendasikan untuk mengintegrasikan fitur tambahan seperti kanal inframerah dan indeks vegetasi, serta mengembangkan model ensemble hibrida guna meningkatkan akurasi klasifikasi.

Kata kunci: *Lactuca sativa*, RGB, Bagging, SVM, klasifikasi warna daun, rekayasa fitur

1. Pendahuluan

Pertanian hidroponik kini menjadi salah satu solusi inovatif dalam menghadapi keterbatasan lahan pertanian konvensional serta meningkatnya permintaan pangan. Selada (*Lactuca sativa L.*) merupakan salah satu tanaman yang populer dalam sistem hidroponik karena memiliki masa tanam yang relatif singkat dan nilai ekonomis yang tinggi (Wijdani & Qurthobi, 2023; Zahra et al., 2023). Peningkatan produktivitas dan mutu hasil panen sangat bergantung pada pengelolaan nutrisi yang tepat. Dalam hal ini, penerapan teknologi nano seperti *Silica Quantum Dots* (Si-QDs) menjadi pendekatan yang menjanjikan dalam mendukung efisiensi penyerapan nutrisi oleh tanaman. Si-QDs yang diperoleh dari sintesis abu sekam padi menggunakan metode *High Energy Milling* (HEM) dengan penambahan KOH menghasilkan partikel berukuran *nano* (0,386–2,5 nm), yang mampu menembus jaringan tanaman secara lebih efektif dan meningkatkan proses metabolisme serta fotosintesis (Amin et al., 2023; Astuti et al., 2022).

Penerapan teknologi berbasis *machine learning* semakin banyak dimanfaatkan dalam sektor pertanian, khususnya dalam menganalisis data terkait respons tanaman. Salah satu indikator yang

sering digunakan adalah warna daun, yang mencerminkan kondisi fisiologis tanaman akibat perlakuan nutrisi tertentu (Nurjannah et al., 2020). Meskipun fitur warna RGB (*Red, Green, Blue*) merupakan data dasar yang umum digunakan, jumlah dimensi yang terbatas dapat menjadi hambatan dalam proses klasifikasi. Oleh karena itu, dalam penelitian ini digunakan pendekatan transformasi ruang warna dan penggabungan antar fitur untuk meningkatkan kualitas informasi yang diperoleh (Asmar et al., 2024).

Fitur yang dianalisis meliputi ruang warna RGB, transformasi ke HSV (*Hue, Saturation, Value*) dan Lab (*Lightness, a, b*), serta rasio antar kanal warna seperti R/G dan G/B guna memperkaya representasi data. Keunggulan utama ruang warna HSV dibandingkan dengan RGB adalah kemampuannya dalam memisahkan informasi warna, kejenuhan, dan kecerahan dengan lebih baik (Mughtar & Mughtar, 2024). Model warna HSV sendiri merupakan pengembangan dari RGB yang lebih mendekati persepsi visual manusia (Rahayu & Mendes, 2021). Sementara itu, ruang warna Lab atau CIELAB mampu merepresentasikan seluruh spektrum warna yang dapat ditangkap oleh mata manusia karena dirancang secara ilmiah oleh Komisi

Internasional tentang Iluminasi (Pambudi et al., 2021).

Meskipun beberapa penelitian sebelumnya telah berhasil memanfaatkan transformasi warna dan metode machine learning untuk klasifikasi daun, sebagian besar masih berfokus pada deteksi tingkat kematangan atau kandungan klorofil, bukan pada analisis pengaruh pupuk berbasis nano terhadap perubahan warna daun. Hal ini menimbulkan kesenjangan (research gap) dalam penerapan machine learning untuk mendeteksi respons tanaman terhadap dosis pupuk silika sekam padi menggunakan data sensor sederhana seperti RGB. Urgensi penelitian ini terletak pada kebutuhan metode klasifikasi yang efisien dan mudah diterapkan di lapangan, tanpa memerlukan citra resolusi tinggi atau perangkat laboratorium mahal.

Penelitian ini secara khusus menerapkan dua algoritma *ensemble learning*, yakni AdaBoost dan Bagging, yang masing-masing dikombinasikan dengan *Support Vector Machine* (SVM) menggunakan *kernel* RBF. Algoritma AdaBoost dipilih karena kemampuannya dalam meningkatkan performa klasifikasi melalui proses pembobotan data secara iteratif, yang menjadikan model lebih adaptif terhadap data berdimensi rendah (Supiyandi et al., 2024). Keunggulan *ensemble* pada AdaBoost juga terlihat dari kemampuannya dalam mengurangi bias dan variansi serta meningkatkan kestabilan prediksi, terutama pada data yang mengandung *noise* (Septiawan & Chairani, 2023).

Sementara itu, Bagging yang dikombinasikan dengan SVM-RBF dinilai efektif dalam mengurangi variabilitas prediksi dan beban komputasi melalui teknik *resampling* pada data latih (Cintari et al., 2024; Meidianingsih & Agustine, 2021; Nugroho & Religia, 2021). Kedua model tersebut akan diuji menggunakan strategi rekayasa fitur yang seragam, sehingga memungkinkan perbandingan performa secara adil. Penelitian ini bertujuan untuk menemukan metode yang paling optimal dalam menangani data klasifikasi warna daun selada dengan jumlah fitur terbatas dan karakteristik non-linear, berdasarkan kombinasi dari ruang warna yang telah ditentukan. Beberapa studi sebelumnya turut menjadi landasan dalam penelitian ini.

Astuti et al. (2022) melakukan sintesis *Silica Quantum Dots* (Si-QDs) dari abu sekam padi menggunakan metode *High Energy Milling* (HEM) dan mengujinya pada tanaman *Lactuca sativa* L. Penelitian ini menunjukkan bahwa penyemprotan Si-QDs sebanyak lima kali memberikan hasil terbaik dalam meningkatkan kandungan klorofil dan efisiensi fotosintesis. Si-QDs mampu menyerap cahaya UV hingga tampak dan mentransfer energi ke klorofil, yang berkontribusi langsung terhadap peningkatan aktivitas foto sistem. Hasil ini memperkuat potensi pemanfaatan *nano-material* dalam pengelolaan nutrisi tanaman hidroponik (Astuti et al., 2022).

Nurjannah et al. (2020) mengembangkan sistem deteksi otomatis kebutuhan nitrogen pada tanaman padi menggunakan sensor TCS3200. Sistem ini mengelompokkan warna daun menjadi delapan skala yang mewakili tingkat kebutuhan pupuk, dari hijau terang hingga hijau gelap. Hasil deteksi digunakan untuk menentukan dosis pupuk nitrogen yang optimal agar tidak terjadi kelebihan atau kekurangan. Pendekatan ini tidak hanya meningkatkan efisiensi pemupukan, tetapi juga mendukung pertanian berkelanjutan (Nurjannah et al., 2020).

Vigo et al. (2022) membandingkan performa Bagging dan AdaBoost pada sebelas *dataset* klasifikasi *multi*-kelas. Hasilnya menunjukkan bahwa Bagging unggul dalam rata-rata akurasi (72,21%) dan *F1-score* (61%) dibandingkan AdaBoost. Meskipun perbedaan tidak signifikan secara statistik, Bagging lebih stabil terhadap variasi *dataset*, sedangkan AdaBoost lebih sensitif terhadap data dengan *noise* rendah. Pemilihan metode disarankan disesuaikan dengan karakteristik dan distribusi data (Vigo et al., 2022).

Hamzah et al. (2024) menyempurnakan klasifikasi kematangan buah alpukat dengan menerapkan SVM dan penambahan jumlah sampel serta fitur. Kombinasi fitur RGB dan HSV terbukti memberikan peningkatan akurasi yang signifikan dibandingkan metode sebelumnya seperti k-NN. *Dataset* diuji dalam dua skenario, masing-masing menunjukkan akurasi di atas 85%. Studi ini menekankan pentingnya pemilihan fitur dan algoritma dalam meningkatkan performa model klasifikasi (Hamzah et al., 2024).


Muchtar dan Muchtar (2024) mengembangkan sistem klasifikasi kematangan cabai merah keriting berdasarkan citra digital menggunakan SVM *multiclass*. Fitur yang digunakan meliputi *mean*, *variance*, dan *range* dari komponen warna RGB. Hasil klasifikasi menunjukkan tingkat akurasi sangat tinggi sebesar 98,33% melalui pengujian *10-fold cross-validation*. Penelitian ini menegaskan bahwa kombinasi fitur RGB efektif untuk mendukung otomatisasi klasifikasi kematangan buah (Muchtar & Muchtar, 2024).

Penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan sistem klasifikasi warna daun berbasis sensor RGB sederhana yang efisien, serta memperkuat pemahaman tentang bagaimana algoritma *ensemble* seperti AdaBoost dan Bagging berperilaku pada data agronomi dengan dimensi rendah.

2. Metodologi Penelitian

Metodologi penelitian yang diterapkan dalam studi ini terdiri dari lima tahap utama, seperti yang diilustrasikan pada Gambar 1 Diagram Blok Tahapan Penelitian. Tahapan tersebut meliputi

pengumpulan data, pemrosesan data, seleksi fitur, pelatihan model, dan evaluasi.



Gambar 1 Diagram Blok Tahapan Penelitian

Tahapan-tahapan ini dirancang untuk memastikan pengolahan data secara sistematis dan menghasilkan model klasifikasi warna daun selada yang optimal.

2.1. Pengumpulan Data

Tahap pertama adalah pengumpulan data menggunakan sensor TCS34725 yang terhubung dengan Arduino Uno. Data yang dikumpulkan berupa nilai RGB dari daun *Lactuca sativa* L. dengan empat perlakuan dosis pupuk Silika Sekam Padi: tanpa penyemprotan, satu kali penyemprotan, tiga kali penyemprotan, dan lima kali penyemprotan. Setiap kelas perlakuan memiliki data yang cukup representatif untuk memastikan distribusi yang seimbang pada *dataset*. Setelah data tersedia, proses pemformatan data dilakukan untuk mengubah teks tidak terstruktur menjadi format *tabular* menggunakan skrip Python, termasuk penghilangan karakter non-numerik (seperti "R=", "G="), standardisasi desimal, dan penghapusan spasi berlebih. *Dataset* dapat dilihat pada Tabel 1 *Dataset* RGB Daun Selada.

Tabel 1 *Dataset* RGB Daun Selada

R	G	B	IR	Perlakuan	Pengambilan
151	149	106,4	73	0	1
151	149	109,8	73	0	1
149	149	106,4	73	0	1

2.2. Pra Pemrosesan Data

Setelah data terkumpul, dilakukan pemrosesan awal untuk memastikan data siap digunakan. Tahapan ini meliputi:

- Normalisasi: Nilai RGB dinormalisasi dengan membagi setiap nilai dengan 255 sehingga berada dalam rentang 0–1.
- Rekayasa Fitur: Meliputi perhitungan rasio warna (R/G, G/B), transformasi ruang warna dari RGB ke HSV dan Lab untuk meningkatkan sensitivitas terhadap perubahan rona dan saturasi warna.
- Pembagian *Dataset*: Data dibagi menggunakan metode *train-test split* dengan rasio 70:30, mempertahankan distribusi kelas secara seimbang.

2.3. Seleksi Fitur

Seleksi fitur dilakukan dengan dua pendekatan utama:

- Kombinasi Fitur: Menghasilkan 63 *subset* yang terdiri dari fitur mentah (RGB), rasio kanal warna, dan transformasi ruang warna.
- Algoritma Seleksi Berbasis Model: Menggunakan teknik seperti PCA (*Principal Component Analysis*) dan *Mutual Information* untuk memilih fitur yang paling relevan berdasarkan karakteristik model.

2.4. Pelatihan Model

Tiga pendekatan algoritma *machine learning* diterapkan pada *dataset*:

- AdaBoost SVM: Dengan *kernel* RBF sebagai base learner.
- Bagging SVM: Dengan 50 *estimator* untuk mengurangi varians model.

2.5. Evaluasi dan Pengujian Model

Validasi model dilakukan dengan *Stratified K-Fold Cross-Validation* (10 lipatan) untuk memastikan stabilitas dan akurasi model. Metrik evaluasi meliputi akurasi, presisi, *recall*, F1-score, dan ROC-AUC. *Hyperparameter tuning* dilakukan untuk mengoptimalkan performa model berdasarkan metrik evaluasi. Setelah validasi, pengujian akhir dilakukan pada data uji (30% *dataset*) untuk mengevaluasi kemampuan generalisasi model.

3. Hasil dan Pembahasan

3.1. Rekayasa Fitur

Rekayasa fitur dilakukan untuk memperkaya *dataset* dan meningkatkan performa model klasifikasi. Proses ini mencakup tiga pendekatan utama

3.1.1. Normalisasi RGB

Normalisasi dilakukan untuk menyeragamkan skala data RGB dalam rentang 0–1. Tabel 2 Hasil Normalisasi RGB menunjukkan hasil normalisasi data secara rinci.

Tabel 2 Hasil Normalisasi RGB

No	R	G	B	r	g	b	Kelas
0	151	149	106	0.59	0.58	0.41	0
				2157	4314	7255	
				2157	4314	0510	
1	151	149	110	0.59	0.58	0.43	0
				0.58	0.58	0.41	
2	149	149	106	4314	4314	7255	0
				0.58	0.58	0.51	
3	149	149	130	0.58	0.58	0.51	0
				4314	4314	0039	
4	149	151	106	0.58	0.59	0.41	0
				4314	3725	7255	

3.1.2. Rasio Kanal RGB

Rasio antar komponen warna, seperti R/G dan G/B, digunakan untuk mendeteksi dominasi warna antar kelas perlakuan. Tabel 3 Hasil Perhitungan Rasio menyajikan hasil rasio kanal RGB secara rinci.

Tabel 3 Hasil Perhitungan Rasio

No	R	G	B	R/G Ratio	G/B Ratio	Perla kuan
0	151	149	106	1.0134 23	1.4003 76	0
1	151	149	110	1.0134 23	1.3572 60	0
2	149	149	106	1.0000 00	1.4003 76	0
3	149	149	130	1.0000 00	1.1456 25	0
4	149	151	106	0.9841 48	1.4229 32	0

3.1.3. Transformasi Warna

Transformasi ruang warna dilakukan untuk meningkatkan sensitivitas model terhadap perubahan rona dan saturasi warna. Dua transformasi utama diterapkan, yaitu HSV dan CIELab. Tabel 4 Hasil Transformasi RGB ke HSV menyajikan hasil transformasi warna secara rinci.

Tabel 4 Hasil Transformasi RGB ke HSV

No	R	G	B	H	S	V	Perlak uan
0	151	149	106	57.30 9417	0.29 5364	0.592 157	0
1	151	149	110	57.0 8879	0.27 2980	0.592 157	0
2	149	149	106	60.0 0000	0.28 5906	0.584 314	0
3	149	149	130	60.0 0000	0.127 114	0.584 314	0
4	149	151	106	63.2 0000	0.29 7226	0.593 725	0

Tabel 5 Hasil Transformasi RGB ke CIELab menyajikan hasil transformasi warna secara rinci.

Tabel 5 Hasil Transformasi RGB ke CIELab

No	R	G	B	cL	cA	cB	Per lak uan
0	151	149	106	60.8 9056 4	- 6.29 9734	22.8 3054 6	0
1	151	149	110	60.9 5389 9	- 5.82 7671	21.0 4401 9	0
2	149	149	106	60.7 2315 5	- 7.11 2026	22.5 7701 3	0
3	149	149	130	61.2 1861 7	- 3.44 7379	10.0 2092 3	0
4	149	151	106	61.3 9541 3	- 8.41 1532	23.4 7647 0	0

3.2. Seleksi Fitur Kombinasi

Agar penggunaan fitur menjadi lebih optimal, penelitian ini melakukan seleksi fitur dengan metode kombinasi *subset* dari keseluruhan *dataset*, menghasilkan 63 kombinasi. Pendekatan ini merujuk pada studi (Asmar et al., 2024), yang menunjukkan bahwa kombinasi fitur optimal dapat meningkatkan performa model. Daftar kombinasi yang dihasilkan dapat dilihat pada Tabel 6.

Tabel 6. Daftar Kombinasi Fitur

No	Kombinasi Fitur
1	R, G, B
2	r, g, b
3	H, S, V
4	cL, ca, cb
5	R/Gratio
6	G/Bratio
7	R, G, B, r, g, b, H, S, V, cL, ca, cb, R/Gratio, G/Bratio
8	R, G, B, r, g, b
9	R, G, B, H, S, V
10	R, G, B, cL, ca, cb
11	R, G, B, R/Gratio
12	R, G, B, G/Bratio
13	r, g, b, H, S, V
14	r, g, b, cL, ca, cb
15	r, g, b, R/Gratio
16	r, g, b, G/Bratio
17	H, S, V, cL, ca, cb
18	H, S, V, R/Gratio
19	H, S, V, G/Bratio
20	cL, ca, cb, R/Gratio
21	cL, ca, cb, G/Bratio
22	R/Gratio, G/Bratio
23	R, G, B, r, g, b, H, S, V
24	R, G, B, r, g, b, cL, ca, cb
25	R, G, B, r, g, b, R/Gratio
26	R, G, B, r, g, b, G/Bratio
27	R, G, B, H, S, V, cL, ca, cb
28	R, G, B, H, S, V, R/Gratio
29	R, G, B, H, S, V, G/Bratio
30	R, G, B, cL, ca, cb, R/Gratio
31	R, G, B, cL, ca, cb, G/Bratio
32	R, G, B, R/Gratio, G/Bratio
33	r, g, b, H, S, V, cL, ca, cb
34	r, g, b, H, S, V, R/Gratio
35	r, g, b, H, S, V, G/Bratio
36	r, g, b, cL, ca, cb, R/Gratio
37	r, g, b, cL, ca, cb, G/Bratio
38	r, g, b, R/Gratio, G/Bratio
39	H, S, V, cL, ca, cb, R/Gratio
40	H, S, V, cL, ca, cb, G/Bratio
41	H, S, V, R/Gratio, G/Bratio
42	cL, ca, cb, R/Gratio, G/Bratio
43	R, G, B, r, g, b, H, S, V, cL, ca, cb
44	R, G, B, r, g, b, H, S, V, R/Gratio
45	R, G, B, r, g, b, H, S, V, G/Bratio
46	R, G, B, r, g, b, cL, ca, cb, R/Gratio
47	R, G, B, r, g, b, cL, ca, cb, G/Bratio
48	R, G, B, r, g, b, R/Gratio, G/Bratio
49	R, G, B, H, S, V, cL, ca, cb, R/Gratio
50	R, G, B, H, S, V, cL, ca, cb, G/Bratio
51	R, G, B, H, S, V, R/Gratio, G/Bratio
52	R, G, B, cL, ca, cb, R/Gratio, G/Bratio
53	r, g, b, H, S, V, cL, ca, cb, R/Gratio
54	r, g, b, H, S, V, cL, ca, cb, G/Bratio
55	r, g, b, H, S, V, R/Gratio, G/Bratio
56	r, g, b, cL, ca, cb, R/Gratio, G/Bratio
57	H, S, V, cL, ca, cb, R/Gratio, G/Bratio

58	R, G, B, r, g, b, H, S, V, cL, ca, cb, R/Gratio
59	R, G, B, r, g, b, H, S, V, cL, ca, cb, G/Bratio
60	R, G, B, r, g, b, H, S, V, R/Gratio, G/Bratio
61	R, G, B, r, g, b, cL, ca, cb, R/Gratio, G/Bratio
62	R, G, B, H, S, V, cL, ca, cb, R/Gratio, G/Bratio
63	r, g, b, H, S, V, cL, ca, cb, R/Gratio, G/Bratio

3.2.1. Adaptive Boosting Support Vector Machine

Semua kombinasi fitur yang didapatkan menghasilkan akurasi rendah, dengan akurasi pelatihan tertinggi sebesar 0.5373 pada model berbasis fitur rgb dan akurasi validasi sebesar 0.5099 selisih rendah dengan nilai RGB mentah (0.5324 untuk pelatihan dan 0.4970 untuk validasi). Kombinasi fitur seperti CLab_G/BRatio tidak mampu meningkatkan performa secara signifikan. AdaBoost gagal meningkatkan performa dasar SVM, menunjukkan bahwa model ini tidak cocok untuk struktur dan fitur data warna seperti dalam *dataset*. Hasil evaluasi dapat dilihat pada Tabel 7. Performa *Train* Model AdaBoost SVM dengan 63 Kombinasi Fitur dan Tabel 8. Performa Validasi Model AdaBoost SVM dengan 63 Kombinasi Fitur.

Tabel 7. Performa *Train* Model AdaBoost SVM dengan 63 Kombinasi Fitur

Feature Group	Model	Train Accuracy	Train Precision	Train Recall	Train F1-Score
rgb	AdaBoost SVM	0.537264	0.746728	0.537264	0.505259
RGB	AdaBoost SVM	0.532414	0.754229	0.532414	0.498267
CLab_G/Bratio	AdaBoost SVM	0.507713	0.653582	0.507713	0.451887
rgb_R/Gratio	AdaBoost SVM	0.487430	0.633290	0.487430	0.433096
RGB_R/Gratio	AdaBoost SVM	0.491183	0.611081	0.491183	0.436076

Tabel 8. Performa Validasi Model AdaBoost SVM dengan 63 Kombinasi Fitur

Feature Group	Model	Val Accuracy	Val Precision	Val Recall	Val F1-Score
rgb	AdaBoost SVM	0.509881	0.683034	0.509881	0.469867
RGB	AdaBoost SVM	0.496990	0.641539	0.496990	0.455149
CLab_G/Bratio	AdaBoost SVM	0.461366	0.534340	0.461366	0.399266
rgb_R/Gratio	AdaBoost SVM	0.454396	0.596217	0.454396	0.396919
RGB_R/Gratio	AdaBoost SVM	0.451386	0.531321	0.451386	0.390588

3.2.2. Bootstrap Aggregating Support Vector Machine

Kombinasi RGB_G/BRatio memberikan akurasi pelatihan 0.8262 dan validasi 0.7212, menunjukkan bahwa rasio warna memberikan kontribusi signifikan. Model ini menunjukkan perbedaan akurasi pelatihan dan validasi yang kecil, mengindikasikan bahwa *overfitting* dapat diminimalkan. Teknik *ensemble* seperti bagging efektif dalam meningkatkan performa SVM, dengan jumlah fitur optimal ($n_features=3$ hingga 5). Hasil evaluasi dapat dilihat pada Tabel 9. Performa *Train* Model Bagging SVM dengan 63 Kombinasi Fitur dan Tabel 10. Performa Validasi Model Bagging SVM dengan 63 Kombinasi Fitur.

Tabel 9. Performa *Train* Model Bagging SVM dengan 63 Kombinasi Fitur

Feature Group	Model	Train Accuracy	Train Precision	Train Recall	Train F1-Score
RGB	Bagging SVM	0.821318	0.830336	0.821318	0.820331
rgb	Bagging SVM	0.821318	0.830336	0.821318	0.820331
CLab	Bagging SVM	0.825286	0.831702	0.825286	0.823902
RGB_G/Bratio	Bagging SVM	0.826168	0.833058	0.826168	0.824775
rgb_G/Bratio	Bagging SVM	0.826168	0.833058	0.826168	0.824775

Tabel 10. Performa Validasi Model Bagging SVM dengan 63 Kombinasi Fitur

Feature Group	Model	Val Accuracy	Val Precision	Val Recall	Val F1-Score
RGB	Bagging SVM	0.724248	0.734922	0.724248	0.722666
rgb	Bagging SVM	0.724248	0.734922	0.724248	0.722666
CLab	Bagging SVM	0.722238	0.728842	0.722238	0.718987
RGB_G/Bratio	Bagging SVM	0.721208	0.730569	0.721208	0.718303
rgb_G/Bratio	Bagging SVM	0.721208	0.730569	0.721208	0.718303

3.3. Seleksi Fitur Algoritma

Seleksi fitur pada penelitian ini menggunakan dua metode, yaitu *Mutual Information* (MI) dan *Principal Component Analysis* (PCA) dengan variasi jumlah fitur atau komponen utama antara 3 hingga 14. Kedua metode tersebut diterapkan pada model AdaBoost-SVM dan Bagging-SVM untuk menentukan kombinasi fitur paling relevan yang mampu meningkatkan akurasi dan kinerja klasifikasi warna daun selada.

3.3.1. Adaptive Boosting Support Vector Machine

Seleksi fitur berbasis *Mutual Information* memberikan hasil terbaik dengan akurasi validasi mencapai 0.4206. PCA dengan 9 komponen utama menghasilkan performa lebih rendah dibandingkan *Mutual Information*. *Mutual Information* lebih efektif dibandingkan PCA dalam menangkap fitur penting untuk model SVM. PCA dengan komponen yang terlalu banyak dapat menyebabkan *overfitting*, mengurangi performa model. Hasil evaluasi dapat dilihat pada Tabel 11. Performa *Train* Model AdaBoost SVM dengan Algoritma Seleksi Fitur dan Tabel 12. Performa Validasi Model AdaBoost SVM dengan Algoritma Seleksi Fitur.

Tabel 11. Performa *Train* Model AdaBoost SVM dengan Algoritma Seleksi Fitur

Feature Group	Model	Train Accuracy	Train Precision	Train Recall	Train F1-Score
ADAB OOST SVM_MUT UAL_INFO_n_features-13	AdaBoost SVM	0.433211	0.516928	0.433211	0.358273
ADAB OOST SVM_MUT UAL_INFO_n_features-3	AdaBoost SVM	0.443009	0.594200	0.443009	0.377722
ADAB OOST SVM_MUT UAL_INFO_n_features-10	AdaBoost SVM	0.423838	0.541710	0.423838	0.343707
ADAB OOST SVM_PCA_n_components-9	AdaBoost SVM	0.414583	0.530359	0.414583	0.331069
ADAB OOST SVM_MUT UAL_INFO_n_features-4	AdaBoost SVM	0.418313	0.529059	0.418313	0.340139

Tabel 12. Performa Validasi Model AdaBoost SVM dengan Algoritma Seleksi Fitur

Feature Group	Model	Val Accuracy	Val Precision	Val Recall	Val F1-Score
ADAB OOST SVM_MUT UAL_INFO_n_features-13	AdaBoost SVM	0.420614	0.519117	0.420614	0.345777
ADAB OOST SVM_MUT UAL_INFO_n_features-3	AdaBoost SVM	0.409762	0.550491	0.409762	0.332984
ADAB OOST SVM_MUT UAL_INFO_n_features-10	AdaBoost SVM	0.406762	0.516958	0.406762	0.324418
ADAB OOST SVM_PCA_n_components-9	AdaBoost SVM	0.405733	0.526128	0.405733	0.324994
ADAB OOST SVM_MUT UAL_INFO_n_features-4	AdaBoost SVM	0.404851	0.491983	0.404851	0.320916

3.3.2. Bootstrap Aggregating Support Vector Machine

Model Bagging SVM dengan 4 fitur berdasarkan *Mutual Information* mencatat akurasi validasi tertinggi sebesar 0.7153, sementara jumlah fitur yang lebih besar justru menurunkan performa validasi. Bagging SVM menunjukkan performa yang stabil dengan *Mutual Information*, terutama pada jumlah fitur kecil (3-5). Seleksi fitur yang terlalu banyak memungkinkan terjadinya redundansi dan menimbulkan *noise* pada data, sehingga bisa menurunkan performa model dalam melakukan klasifikasi. Hasil evaluasi dapat dilihat pada Tabel 13 dan Tabel 14.

Tabel 13. Performa *Train* Model Bagging SVM dengan Algoritma Seleksi Fitur

Feature Group	Model	Train Accuracy	Train Precision	Train Recall	Train F1-Score
BAGGING SVM_MUTUAL_INFORMATION_features-4	Bagging SVM	0.828924	0.834822	0.828924	0.827536
BAGGING SVM_MUTUAL_INFORMATION_features-3	Bagging SVM	0.821538	0.829629	0.821538	0.820505
BAGGING SVM_MUTUAL_INFORMATION_features-9	Bagging SVM	0.830467	0.836529	0.830467	0.829058
BAGGING SVM_MUTUAL_INFORMATION_features-8	Bagging SVM	0.830467	0.836301	0.830467	0.829083
BAGGING SVM_MUTUAL_INFORMATION_features-5	Bagging SVM	0.829585	0.835053	0.829585	0.828301

Tabel 14. Performa *Train* Model Bagging SVM dengan Algoritma Seleksi Fitur

Feature Group	Model	Val Accuracy	Val Precision	Val Recall	Val F1-Score
BAGGING SVM_MUTUAL_INFORMATION_features-4	Bagging SVM	0.715257	0.724706	0.715257	0.711194
BAGGING SVM_MUTUAL_INFORMATION_features-3	Bagging SVM	0.714297	0.725605	0.714297	0.711816

BAGGING SVM_MUTUAL_INFORMATION_features-9	Bagging SVM	0.710307	0.727569	0.710307	0.705464
BAGGING SVM_MUTUAL_INFORMATION_features-8	Bagging SVM	0.709327	0.725399	0.709327	0.704492
BAGGING SVM_MUTUAL_INFORMATION_features-5	Bagging SVM	0.709307	0.720297	0.709307	0.705100

3.4. Model Final

Penelitian ini mengevaluasi performa empat model *machine learning* menggunakan *Hyperparameter tuning* dan validasi pada data RGB untuk klasifikasi warna daun. Analisis dilakukan pada model AdaBoost SVM dan Bagging SVM, masing-masing dengan fitur rgb. Berikut adalah ringkasan hasil dan pembahasan:

3.4.1. AdaBoost SVM


Model AdaBoost SVM menunjukkan performa terendah dibandingkan model lain dalam penelitian ini. Tabel 15 menampilkan hasil evaluasi pada data latih dan data uji. Pada data latih, akurasi mencapai 82,24%, sedangkan pada data uji turun menjadi 70,90%. Penurunan ini menghasilkan gap performa sekitar 11%, yang mengindikasikan *overfitting* cukup signifikan. Metrik lain seperti *precision*, *recall*, dan F1-score juga mengalami penurunan sekitar 10% dari pelatihan ke pengujian.

Penurunan konsisten pada seluruh metrik memperlihatkan bahwa kombinasi *AdaBoost* dengan SVM cenderung tidak stabil tanpa regularisasi tambahan. Model terlalu berfokus pada pola data latih sehingga kemampuan generalisasinya berkurang.

Tabel 15. Performa Final Model AdaBoost SVM

Feature Group	Model	Train Accuracy	Train Precision	Train Recall	Train F1-Score
AdaBoost SVM	AdaBoost SVM	0.822421	0.832009	0.822421	0.820673
AdaBoost SVM	AdaBoost SVM	0.709007	0.729631	0.709007	0.706228

Setelah melihat isi Tabel 15. Performa Final Model AdaBoost SVM, dapat disimpulkan bahwa AdaBoost SVM tidak mampu menjaga keseimbangan antara bias dan varians. Hal ini diperkuat oleh learning curve pada Gambar 2 *Learning curve* Final Model AdaBoost SVM, yang menunjukkan train score tetap tinggi namun test score naik perlahan dengan gap akhir tetap besar. Kondisi ini menggambarkan model yang mempelajari pola secara berlebihan pada data latih.

Gambar 2 *Learning curve* Final Model AdaBoost SVM

3.4.2. Bagging SVM


Model *Bagging* SVM memberikan performa paling stabil dan seimbang di antara seluruh model yang diuji. Tabel 15 menunjukkan bahwa akurasi pelatihan sebesar 77,53% hanya turun sedikit menjadi 73,67% pada pengujian, dengan perbedaan performa sekitar 3–4%. Penurunan yang kecil ini memperlihatkan bahwa model memiliki kemampuan generalisasi yang baik.

Precision, *recall*, dan *F1-score* juga tetap konsisten, hanya mengalami penurunan minimal. Hal ini menunjukkan bahwa *Bagging* mampu mereduksi varians bawaan SVM, sehingga menghasilkan prediksi yang lebih stabil pada data baru.


Tabel 16. Performa Final Model Bagging SVM

Feature Group	Model	Train Accuracy	Train Precision	Train Recall	Train F1-Score
Bagging_SVM_Best	Bagging SVM	0.7753	0.7835	0.7753	0.7741
		51	41	51	40
Bagging_SVM_Best	Bagging SVM	0.7367	0.7451	0.7367	0.7342
		21	59	21	94

Dari Tabel 16. Performa Final Model Bagging SVM, terlihat bahwa Bagging SVM memiliki bias-variance trade-off paling optimal. *Learning curve* pada Gambar 3 *Learning curve* Fina Model Bagging SVM juga mendukung kesimpulan ini, menunjukkan tren train score yang menurun perlahan dan test score yang meningkat stabil, dengan gap akhir kecil (~3,8%). Karakteristik ini menandakan model yang robust dan tidak mengalami overfitting.

Gambar 3 *Learning curve* Fina Model Bagging SVM

3.4.3. Analisis Komparatif

Gambar 4 Hasil Komparasi Kedua Model (*Train-Test*)

Dari Gambar 4 Hasil Komparasi Kedua Model (*Train-Test*), terlihat bahwa model Bagging-SVM mengungguli AdaBoost-SVM pada seluruh metrik evaluasi. Peningkatan akurasi sebesar 2,77% disertai stabilitas yang lebih baik menunjukkan bahwa pendekatan resampling pada Bagging dapat menekan efek overfitting tanpa menurunkan kompleksitas model. Secara umum, Bagging cenderung lebih cocok untuk dataset dengan variasi alami antar kelas seperti warna daun, karena model tidak terlalu bergantung pada bobot individu dari data yang mungkin mengandung noise.

Sebaliknya, AdaBoost-SVM menunjukkan kelemahan pada dataset non-linear berdimensi rendah seperti RGB murni. Model ini lebih mudah terjebak dalam pembelajaran terhadap pola kecil yang tidak representatif. Fenomena tersebut juga dilaporkan oleh Vigo et al. (2022), yang menemukan bahwa Bagging memberikan akurasi dan F1-score lebih tinggi daripada AdaBoost pada sebagian besar dataset multi-kelas.

Hasil penelitian ini juga sejalan dengan Hamzah et al. (2024) yang menyatakan bahwa kombinasi fitur sederhana seperti RGB dan HSV mampu mencapai performa optimal jika dikombinasikan dengan algoritma ensemble yang stabil. Namun, berbeda dengan Muchtar & Muchtar (2024) yang memperoleh akurasi hingga 98% pada citra buah cabai, penelitian ini menggunakan data numerik sensor RGB sehingga rentang variasi warna lebih sempit dan akurasi lebih moderat.

Secara keseluruhan, hasil ini menegaskan bahwa Bagging-SVM merupakan pilihan yang lebih tepat untuk data sensor warna daun yang memiliki karakteristik non-linear dan variabilitas sedang,

karena memberikan keseimbangan antara bias dan variansi yang optimal.

4. Kesimpulan dan Saran

Hasil evaluasi menunjukkan adanya perbedaan kinerja yang cukup jelas antara kedua algoritma ensemble yang digunakan. Model AdaBoost-SVM menghasilkan akurasi uji sebesar 70,90%, dengan penurunan performa sekitar 11% dibandingkan hasil pelatihan. Hal ini mengindikasikan adanya overfitting, di mana model terlalu menyesuaikan diri terhadap data latih namun kurang mampu menggeneralisasi data uji. Sebaliknya, model Bagging-SVM menunjukkan kinerja yang lebih stabil dengan akurasi uji 73,67%, presisi 74,52%, recall 73,67%, dan F1-score 73,43%. Selisih performa antara data latih dan uji hanya sekitar 3,87%, menandakan generalisasi yang baik.

Secara konseptual, perbedaan kinerja tersebut disebabkan oleh mekanisme kerja kedua algoritma. AdaBoost melakukan pembobotan adaptif pada data yang salah klasifikasi, sehingga sensitif terhadap outlier atau variasi warna yang ekstrem. Hal ini menyebabkan model cenderung tidak stabil pada dataset yang memiliki variabilitas tinggi. Sebaliknya, Bagging memanfaatkan proses bootstrap sampling yang menghasilkan beberapa subset data latih untuk membangun model secara paralel, sehingga mampu menurunkan variansi dan meningkatkan kestabilan prediksi.

Dari hasil tersebut, dapat disimpulkan bahwa Bagging-SVM lebih unggul untuk data RGB daun selada yang memiliki karakteristik non-linear dan variabilitas antar kelas yang cukup tinggi. Temuan ini sejalan dengan studi Vigo et al. (2022) yang menyebutkan bahwa Bagging lebih tangguh terhadap fluktuasi data dibandingkan AdaBoost. Selain itu, penelitian ini juga menunjukkan bahwa transformasi ruang warna seperti HSV dan CIELab tidak memberikan peningkatan signifikan terhadap akurasi akhir, yang mengindikasikan bahwa fitur dasar RGB masih cukup representatif untuk klasifikasi warna daun menggunakan model ensemble berbasis SVM.

5. Daftar Pustaka

- Amin, M., Mulyawan, R., Santari, P. T., Manwan, S. W., & Prasetyo, R. A. (2023). Pemupukan Silikon dalam Meningkatkan Pertumbuhan dan Hasil Tanaman Sorgum. *Vegetalika*, 12(3), 325. <https://doi.org/10.22146/veg.84207>
- Asmar, M., Kurniawan, M. R., Ashari, R. N., Akbar, M., & Intam, R. N. J. S. (2024). Klasifikasi Tingkat Aroma Daun Jeruk Purut Menggunakan Metode Jaringan Saraf Tiruan Backpropagation. *Journal of Deep Learning, Computer Vision and Digital Image Processing*, 2(2). <https://doi.org/10.61255/decoding>
- Astuti, E. S., Sonief, A. A. ad, Sarosa, M., Ngafwan, N., & Wardana, I. N. G. (2022). Synthesis, characterization and energy gap of *Silica Quantum Dots* from rice husk. *Bioresource Technology Reports*, 20. <https://doi.org/10.1016/j.biteb.2022.101263>
- Cintari, N. P., Alifviansyah, K., Tsabitah, D. U., Sartono, B., & Firdawanti, A. R. (2024). Analisis Perbandingan Kinerja Metode Ensemble Bagging dan Boosting pada Klasifikasi Bantuan Subsidi Listrik di Kabupaten/Kota Bogor. *The Indonesian Journal of Computer Science*, 13(6). <https://doi.org/10.33022/ijcs.v13i6.4537>
- Hamzah, A., Susanti, E., & Lestari, R. M. (2024). Klasifikasi Kematangan Buah Alpukat Mentega Berdasarkan Fitur Warna Menggunakan Support Vector Machine. *Jurnal Innovation and Future Technology (IFTECH)*, 6(1), 108–120.
- Meidianingsih, Q., & Agustine, D. (2021). Study of Bagging Application in the Safe-Level Smote Method in Handling Unbalanced Classification. *Indonesian Journal of Statistics and Its Applications*, 5(1), 105–116. <https://doi.org/10.29244/ijsa.v5i1p105-116>
- Muchtar, M., & Muchtar, R. A. (2024). Perbandingan Metode KNN Dan SVM Dalam Klasifikasi Kematangan Buah Mangga Berdasarkan Citra HSV Dan Fitur Statistik. *Jurnal Informatika Dan Teknik Elektro Terapan*, 12(2). <https://doi.org/10.23960/jitet.v12i2.4010>
- Nugroho, A., & Religia, Y. (2021). Analisis Optimasi Algoritma Klasifikasi Naive Bayes menggunakan Genetic Algorithm dan Bagging. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 5(3), 504–510. <https://doi.org/10.29207/resti.v5i3.3067>
- Nurjannah, Faizal, & Afif, N. (2020). Sistem Prediksi Takaran Pupuk Pada Tanaman Padi Berdasarkan Warna Daun Menggunakan Arduino Nano. *AGENTS: Journal of Artificial Intelligence and Data Science*, 1(1). <https://doi.org/https://doi.org/10.24252/jagti.v1i1.14>
- Pambudi, N. A., Pranoto, Y. A., & Sasmito, A. P. (2021). Pengenalan Tingkat Kematangan Buah Kopi Berdasarkan Fitur Warna Cielab Dengan K-Means Clustering. *Jurnal Mahasiswa Teknik Informatika*, 5(2).
- Rahayu, T. K., & Mendes, J. A. (2021). Deteksi Penyakit Tanaman Rambutan Berdasarkan Citra Daun Menggunakan Fuzzy K-Nearest Neighbour. *MUSTEK ANIM HA*, 10(2), 41–46.
- Septiawan, Y., & Chairani. (2023). Perbandingan Akurasi Metode Deteksi Ujaran Kebencian

- dalam Postingan Twitter Menggunakan Metode SVM dan Decision Trees yang Dioptimalkan dengan Adaboost. *JURNAL TEKNIKA*, 17(2), 287–299.
- Supiyandi, Hasibuan, M. S., & Harahap, H. (2024). Penerapan Metode Haar-Like Feature Dan Algoritma Adaboost Dalam Penentuan Klasifikasi Hama Tanaman Kopi. In *Journal of Science and Social Research* (Issue 1). <http://jurnal.goretanpena.com/index.php/JSSR>
- Vigo, O., Lukas, S., Krisnadi, D., & Widjaja, P. (2022). Perbandingan Performa Bagging Dan Adaboost Untuk Klasifikasi Data *Multi-Class*. *INFORMATION SYSTEM DEVELOPMENT*, 7(2). <https://doi.org/10.19166/xxxx>
- Wijdani, H. E., & Qurthobi, A. (2023). Kontrol Nutrisi Dan PH Sistem Hidroponik Nutrient Film Technique (NFT) Tanaman Tomat Ungu (Indigo Rose) Menggunakan Logika Fuzzy. *E-Proceeding of Engineering*, 10(5), 4418–4425.
- Zahra, N., Muthiadin, C., & Ferial, F. (2023). Budidaya tanaman selada (*Lactuca sativa L.*) secara hidroponik dengan sistem DFT di BBPP Batangkaluku. *Filogeni: Jurnal Mahasiswa Biologi*, 3(1), 18–22. <https://doi.org/10.24252/filogeni.v3i1.29922>