



Klasifikasi Tingkat Kematangan Nanas Berdasarkan Citra Warna dengan Metode SVM

Zulkhan Arbi Toyibun Abdillah^{1*}, Adi Prihandono²

¹Universitas Dian Nuswantoro

Jalan Imam Bonjol No. 207 Semarang, e-mail: 111202214244@mhs.dinus.ac.id

²Universitas Dian Nuswantoro

Jalan Imam Bonjol No. 207 Semarang, e-mail: adi.prihandono@dsn.dinus.ac.id

ARTICLE INFO

History of the article :

Received 1 Desember 2026

Received in revised form 8 Januari 2026

Accepted 14 Januari 2026

Available online 31 Januari 2026

Keywords:

Support Vector Machine; Klasifikasi Nanas; Pengolahan Citra; Principal Component Analysis (PCA); Kematangan Buah

* Correspondence:

Telepon:

+62 85654258138

E-mail:

111202214244@mhs.dinus.ac.id

ABSTRACT

Penentuan kematangan nanas manual bersifat subjektif dan tidak konsisten. Penelitian ini bertujuan membangun sistem klasifikasi nanas (Matang, Setengah Matang, Mentah) yang objektif menggunakan Support Vector Machine (SVM) berbasis citra warna. Metode ini menggunakan 2044 citra augmentasi. Fitur warna mentah (30.000 fitur) diekstraksi dan direduksi menggunakan Principal Component Analysis (PCA) menjadi 51 komponen untuk mengatasi *overfitting*. Model SVM (RBF) dioptimalkan dengan GridSearchCV. Hasilnya, model SVM (RBF Tuned) terpilih mencapai akurasi 81.78% pada data uji, secara signifikan mengungguli KNN (75.79%). Model ini mencapai "Good Fit" dengan selisih *overfit* rendah (11.04%). Kesimpulannya, kombinasi SVM dan PCA valid dan efektif.

INTRODUCTION

Nanas (*Ananas comosus*) merupakan salah satu komoditas hortikultura unggulan di Indonesia. Nilai ekspor buah ini berkontribusi signifikan terhadap perekonomian, dimana nanas memiliki pangsa ekspor yang besar dari total nilai ekspor produk hortikultura Indonesia [1]. Peningkatan produksi nanas yang terus terjadi dalam beberapa tahun terakhir, seperti yang dilaporkan oleh Badan Pusat Statistik (BPS) [2], menuntut adanya manajemen pascapanen yang efektif untuk menjaga kualitas hasil panen.

Faktor kunci dalam manajemen pascapanen nanas adalah penentuan tingkat kematangan yang tepat. Kematangan buah nanas adalah proses yang berlangsung dalam beberapa tahap, ditandai dengan perubahan warna kulit dari hijau tua, menjadi hijau kekuningan, hingga oranye kekuning-kuningan saat matang penuh [3]. Tingkat kematangan ini tidak hanya mempengaruhi rasa dan umur simpan buah, tetapi juga menjadi standar utama untuk menentukan kelayakan ekspor dan harga jual di pasar, baik lokal maupun internasional [1].


Hingga saat ini, metode yang dominan digunakan untuk menentukan kematangan nanas di tingkat petani atau industri skala kecil masih bersifat tradisional dan manual. Proses ini umumnya

mengandalkan pengamatan visual (mata manusia) terhadap warna dan tekstur kulit, perabaan fisik, serta perkiraan umur tanaman[4]. Ketergantungan pada metode konvensional ini menimbulkan permasalahan utama berupa variasi hasil penilaian antar individu serta ketidakkonsistenan dalam proses sortasi, terutama ketika dilakukan dalam jumlah besar atau oleh beberapa operator dengan pengalaman berbeda[5]. Selain itu, kajian literatur menyatakan bahwa penentuan tingkat kematangan secara manual cenderung bersifat subjektif dan tidak konsisten, sehingga mendorong pengembangan sistem otomatis yang lebih akurat dan efisien[6].

Untuk mengatasi kelemahan metode manual, penelitian di bidang teknologi pertanian telah beralih ke solusi yang lebih objektif dan otomatis menggunakan *computer vision* dan *machine learning*. Beberapa penelitian seperti pada klasifikasi kematangan buah tomat menggunakan Support Vector Machine (SVM) telah menunjukkan hasil yang baik dalam pengenalan tingkat kematangan berbasis ciri citra digital [7]. Demikian pula, penelitian pada jeruk lemon menunjukkan bahwa SVM mampu memberikan akurasi tinggi hingga 97% dalam menentukan tingkat kematangan, mengungguli metode lain seperti Naïve Bayes [8]. Penelitian lain pada buah tomat juga menunjukkan keberhasilan metode Backpropagation (Jaringan Syaraf Tiruan) yang mampu mencapai akurasi 97.29% dengan memanfaatkan fitur warna RGB dan HIS [9]. Pada komoditas lain seperti buah naga, pendekatan yang lebih sederhana menggunakan ekstraksi fitur HSV dan klasifikasi K-Nearest Neighbor (KNN) juga terbukti sangat efektif dengan akurasi 96.7% [10]. Bahkan, untuk klasifikasi yang lebih kompleks seperti buah manggis, penerapan metode Deep Learning (CNN) yang didukung oleh augmentasi data secara ekstensif dilaporkan mampu mencapai akurasi hingga 100% [11]. Melihat keberhasilan Support Vector Machine (SVM) pada berbagai komoditas buah dan potensi *computer vision* untuk pemilahan nanas, penerapan metode SVM untuk klasifikasi tingkat kematangan nanas menjadi area penelitian yang relevan. Studi sebelumnya menunjukkan bahwa SVM mampu memberikan performa yang kompetitif dalam klasifikasi tingkat kematangan buah jika dibandingkan dengan metode lain, seperti yang ditunjukkan pada penelitian klasifikasi kematangan buah mangga yang membandingkan SVM dengan Naïve Bayes dan menghasilkan kinerja SVM yang lebih stabil [12]. Beberapa penelitian sebelumnya telah mulai mengeksplorasi penggunaan SVM dan K-Nearest Neighbor (K-NN) untuk identifikasi kematangan nanas dengan hasil yang bervariasi [3]. Oleh karena itu, penelitian ini mengusulkan sebuah sistem klasifikasi tingkat kematangan nanas yang berfokus secara spesifik pada metode Support Vector Machine (SVM) berdasarkan analisis fitur dari citra warna. Tujuan dari penelitian ini adalah untuk membangun dan mengevaluasi model SVM yang akurat dan efisien dalam mengklasifikasikan tingkat kematangan nanas, yang dapat menjadi dasar bagi pengembangan sistem sortir otomatis yang objektif dan konsisten.

RESEARCH METHODS

Penelitian ini merupakan penelitian eksperimental untuk membangun sistem klasifikasi kematangan buah nanas menggunakan metode *machine learning* klasik. Metode yang digunakan dalam penelitian ini mengikuti alur sistematis seperti yang ditunjukkan pada flowchart. Alur ini dirancang untuk membangun model klasifikasi yang optimal dan mengatasi masalah overfitting yang umum terjadi pada dataset citra



Gambar 1 Tahapan Penelitian




A. Identifikasi Masalah

Tujuan dari penelitian ini adalah untuk merancang dan membangun sebuah sistem klasifikasi otomatis menggunakan *machine learning* klasik. Sistem ini bertujuan untuk menentukan tingkat kematangan buah nanas (Mentah, SetengahMatang, Matang) secara akurat hanya berdasarkan citra (gambar) visual yang diambil dari kamera handphone.

B. Pengumpulan Dan Augmentasi Data

Langkah awal adalah pengumpulan data (*data acquisition*). Dataset awal terdiri dari 511 gambar buah nanas yang dikumpulkan secara manual Menggunakan kamera Handphone, dibagi menjadi tiga kelas kematangan: 'Matang', 'Mentah', dan 'SetengahMatang'. Dataset ini mencakup berbagai format gambar, termasuk file HEIC (*High-Efficiency Image File*).

Tabel 1. Gambar Data Asli

| Kelas | Gambar Asli |
|-----------------|--|
| Mentah |  |
| Setengah Matang |  |
| Matang |  |

Untuk mengatasi keterbatasan jumlah data dan mengurangi risiko overfitting, dilakukan proses augmentasi data. Teknik augmentasi yang diterapkan meliputi transformasi rotasi, pembalikan citra (*horizontal flipping*), serta perubahan intensitas warna (*color jitter*), seperti penyesuaian kecerahan dan kontras. Proses ini bertujuan untuk meningkatkan keragaman data dan mensimulasikan variasi kondisi pencahayaan yang mungkin terjadi pada lingkungan nyata. Melalui proses augmentasi ini, jumlah dataset meningkat dari 511 citra asli menjadi 2044 citra, yang selanjutnya digunakan pada tahap pelatihan dan pengujian model.

C. Preprocessing & Ekstrasi Fitur

Metodologi ini menggunakan pendekatan *machine learning* klasik yang bergantung pada ekstraksi fitur secara manual.

- **Pemuatan dan Standardisasi Citra:** Setiap gambar (asli dan augmentasi) dimuat, dikonversi ke format BGR standar, dan diubah ukurannya (*resize*) menjadi 100x100 piksel.
- **Perataan Fitur (*Feature Flattening*):** Setiap gambar berukuran (100, 100, 3) diratakan (*flattened*) menjadi vektor fitur satu dimensi, menghasilkan **30.000 fitur** per gambar.
- **Standardisasi Fitur:** Vektor 30.000 fitur tersebut distandarisasi menggunakan StandardScaler untuk memastikan setiap fitur memiliki rata-rata 0 dan standar deviasi 1.
- **Reduksi Dimensi (PCA):** Menggunakan 30.000 fitur secara langsung tidak efisien dan menyebabkan *overfitting*. Oleh karena itu, *Principal Component Analysis* (PCA) diterapkan. Melalui serangkaian eksperimen, ditemukan bahwa $n_components=0.70$ (mempertahankan 70% varians) adalah pengaturan optimal. Ini mengurangi dimensi fitur dari 30.000 menjadi **51 komponen utama (fitur)**.

D. Splitting Data

Dataset 2044 gambar (yang telah menjadi 51 fitur PCA) dibagi menjadi data latih (*train*) dan data uji (*test*) dengan rasio 60:40. Ini menghasilkan **1226 sampel latih** (untuk melatih model) dan **818 sampel uji** (untuk evaluasi akhir)

E. Optimasi Parameter (GridSearchCV)

Untuk memperoleh performa klasifikasi yang optimal dan mencegah *overfitting*, dilakukan optimasi parameter pada model Support Vector Machine (SVM) menggunakan metode GridSearchCV. Proses optimasi ini dilakukan dengan skema k-fold cross-validation ($k = 5$), sehingga setiap kombinasi parameter dievaluasi secara menyeluruh pada data latih.

Parameter yang dioptimasi meliputi parameter regularisasi C dan parameter kernel gamma pada SVM dengan kernel Radial Basis Function (RBF). Beberapa kombinasi nilai C dan gamma diuji untuk menemukan parameter yang memberikan kinerja terbaik berdasarkan skor akurasi validasi silang. Model dengan kombinasi parameter terbaik selanjutnya dipilih sebagai model final dan digunakan untuk evaluasi pada data uji.

F. Pemilihan Model Terbaik

Selama proses optimasi, beberapa model klasifikasi *machine learning* klasik dievaluasi. Fokus utama adalah pada Support Vector Machine (SVM) dengan kernel Radial Basis Function (RBF), yang secara konsisten terbukti memberikan performa (skor validasi silang) tertinggi dibandingkan *K-Nearest Neighbors* (KNN) dan *Random Forest*.

G. Evaluasi Model

Model terbaik yang dihasilkan oleh GridSearchCV (berdasarkan skor validasi silang tertinggi dari langkah 5 dan 6) kemudian dievaluasi kinerjanya menggunakan data uji (818 sampel) yang belum pernah dilihat sebelumnya. Metrik evaluasi utama meliputi:

- Laporan Tiga Akurasi: Perbandingan antara Akurasi Validasi, Akurasi Latih, dan Akurasi Uji untuk menganalisis tingkat *overfitting*.
- Laporan Klasifikasi: Detail *precision*, *recall*, dan *f1-score* untuk setiap kelas.
- Confusion Matrix: Untuk memvisualisasikan di mana model paling sering melakukan kesalahan klasifikasi.

RESULTS

Setelah melalui proses pelatihan dan optimasi seperti yang dijelaskan pada bagian metode, dilakukan serangkaian evaluasi untuk menentukan model klasifikasi terbaik. Bagian ini memaparkan temuan dan hasil dari eksperimen tersebut. Sebagai langkah awal, dilakukan perbandingan performa dari beberapa algoritma *machine learning* klasik untuk memvalidasi pemilihan model. Hasil perbandingan akurasi dari setiap model yang diuji menggunakan data uji disajikan pada Tabel 2.

Tabel 2. Perbandingan Akurasi Model Klasifikasi pada Data Uji

| Model Klasifikasi | Akurasi Test (81.78%%) |
|---------------------------|------------------------|
| SVM (RBF Tuned) | [81.78%] |
| SVM (Linear Tuned) | [59.90%] |
| K-Nearest Neighbors (KNN) | [75.79%] |
| Random Forest | [77.14%] |
| Gaussian Naive Bayes | [64.06%] |

Perbandingan performa antar model ditunjukkan pada Tabel 2. Berdasarkan hasil pengujian, model **SVM dengan kernel RBF yang telah dituning** menghasilkan akurasi tertinggi pada data uji sebesar **81,78%**, mengungguli K-Nearest Neighbors (75,79%), Random Forest (77,14%), dan Gaussian Naive Bayes (64,06%). Hasil ini menunjukkan bahwa SVM (RBF) memiliki kemampuan generalisasi yang lebih baik pada dataset citra nanas dibandingkan metode lain yang diuji.

Tabel 3. Hasil Klasifikasi Rinci Model SVM (RBF) Final

| Kelas | Precision | Recall | F1-Score | Support (Jumlah Sampel) |
|---------------------------------|-----------|--------|----------|-------------------------|
| Matang | 0.82 | 0.79 | 0.81 | 269 |
| Mentah | 0.78 | 0.83 | 0.80 | 283 |
| SetengahMatang | 0.86 | 0.83 | 0.85 | 266 |
| Average/Total (Weighted Avg) | 0.82 | 0.82 | 0.82 | 818 |

Evaluasi lebih lanjut terhadap model SVM (RBF) disajikan pada Tabel 3, yang menunjukkan nilai precision, recall, dan F1-score untuk setiap kelas kematangan. Kelas Setengah Matang memperoleh performa terbaik dengan F1-score sebesar 0,85, sementara kelas Mentah memiliki F1-score terendah sebesar 0,80, mengindikasikan bahwa kelas ini paling sulit dibedakan oleh model.

Tabel 4. Hasil Eksperimen Tuning PCA dan SVM (RBF) untuk Mengatasi Overfitting


| Eksperimen | Data | PCA (components) | Grid C (RBF) | Akurasi Train (%) | Akurasi Test (%) | Selisih (Overfit) (%) |
|-----------------------|-------|---------------------|-----------------|----------------------|------------------------|-----------------------------|
| Baseline | 2000+ | 0.80 | [0.6...1.0] | 91.35% | 79.22% | 12.14% |
| Model Final | 2000+ | 0.70 | [0.2...0.6] | 92.82% | 81.78% | 11.04% |
| Eksperimen Gagal 1 | 2000+ | 0.80 | [0.2...0.6] | 91.35% | 79.22% | 12.14% |

| Eksperimen | Data | PCA (components) | Grid C (RBF) | Akurasi Train (%) | Akurasi Test (%) | Selisih (Overfit) (%) |
|--------------------|-------|------------------|--------------|-------------------|------------------|-----------------------|
| Eksperimen Gagal 2 | 1000+ | 0.70 | [C besar] | 100.00% | 86.06% | 13.94% |

Tabel 4 menyajikan inti dari metodologi penelitian dan menceritakan "kisah" tentang bagaimana Model Final (model terbaik) berhasil ditemukan. Tabel ini merangkum serangkaian eksperimen yang dilakukan untuk mengatasi masalah *overfitting* (model menghafal).

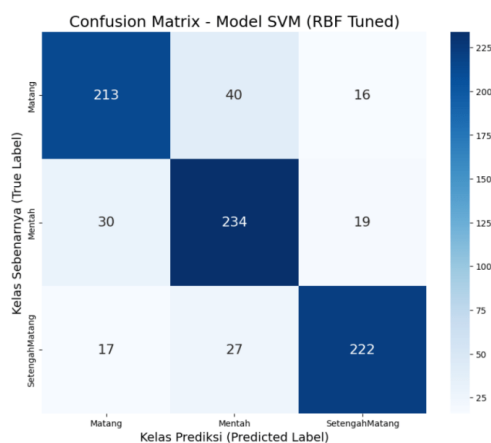
Tabel ini menunjukkan bahwa eksperimen awal (seperti Eksperimen Gagal 2) menderita *overfitting* parah, yang dibuktikan dengan Akurasi Train 100%. Meskipun akurasi tesnya (86.06%) terlihat tinggi, hasil ini tidak dapat diandalkan karena model hanya "menghafal", bukan "belajar".

Tabel ini kemudian membuktikan bahwa Model Final adalah yang paling unggul. Dengan menggabungkan lebih banyak data (2000+), reduksi PCA yang lebih agresif (0.70), dan parameter C yang lebih ketat ([0.2-0.6]), model ini berhasil menghentikan "penghafalan" (Akurasi Train turun ke 92.82%) dan mencapai akurasi "jujur" yang tinggi (Akurasi Test 81.78%) dengan selisih *overfit* terendah (11.04%).



Gambar 2. Visualisasi sebaran data setelah reduksi dimensi PCA 2D

Hasil dari proses PCA ini divisualisasikan pada Gambar 2. Plot sebaran (scatter plot) ini menunjukkan bahwa 51 fitur baru tersebut berhasil mengelompokkan data berdasarkan kelasnya; terlihat jelas bahwa kelas 'SetengahMatang' (kuning) membentuk kluster yang terpisah di sisi kanan, membuktikan bahwa fitur PCA ini informatif.



Gambar 3. Confusion Matrix Hasil Klasifikasi Model SVM (RBF Tuned)

Distribusi kesalahan klasifikasi divisualisasikan menggunakan confusion matrix pada Gambar 3. Model mampu mengklasifikasikan sebagian besar sampel dengan benar, namun kesalahan terbesar terjadi pada kelas Matang yang salah diprediksi sebagai Mentah. Hal ini menunjukkan adanya kemiripan karakteristik warna antara kedua kelas tersebut.



Gambar 3. Sampel Citra Hasil Augmentasi untuk Setiap Kelas Kematangan

Gambar 4 menampilkan contoh citra hasil augmentasi untuk setiap kelas kematangan nanas. Perubahan warna ekstrem yang terlihat pada beberapa citra, seperti dominasi warna kebiruan, merupakan dampak dari teknik augmentasi data (misalnya *color jitter* dan perubahan intensitas warna) yang bertujuan meningkatkan keragaman data dan ketahanan model terhadap variasi pencahayaan. Warna tersebut tidak merepresentasikan kondisi warna asli buah nanas, dan data citra asli telah diverifikasi tidak mengandung anomali warna.

Hasil akurasi sebesar 81,78% yang diperoleh pada penelitian ini sejalan dengan temuan penelitian sebelumnya yang menunjukkan efektivitas Support Vector Machine (SVM) dalam klasifikasi tingkat kematangan buah berbasis citra. pada klasifikasi kematangan buah kelapa sawit melaporkan akurasi yang lebih tinggi, yaitu sebesar 93%, dengan memanfaatkan kombinasi fitur warna dan tekstur[13]. Perbedaan tingkat akurasi tersebut dapat dipengaruhi oleh karakteristik objek dan fitur yang digunakan, di mana penelitian ini hanya mengandalkan informasi warna citra nanas yang memiliki variasi warna tidak seragam dan saling tumpang tindih antar tingkat kematangan. Hal ini menunjukkan bahwa meskipun SVM terbukti efektif pada berbagai komoditas buah, kompleksitas visual objek dan pemilihan fitur sangat berpengaruh terhadap performa klasifikasi.

DISCUSSION

Hasil penelitian ini menunjukkan bahwa metode Support Vector Machine (SVM) yang diusulkan berhasil menjawab tantangan utama yang diidentifikasi dalam pendahuluan, yaitu

subjektivitas dan inkonsistensi pemilahan nanas secara manual. Model SVM (RBF Tuned) mencapai akurasi 81.78%, membuktikan bahwa klasifikasi kematangan nanas secara otomatis dan objektif berdasarkan citra warna adalah pendekatan yang valid. Seperti yang ditunjukkan pada Tabel 2, performa SVM (RBF Tuned) secara signifikan mengungguli model klasifikasi klasik lainnya, termasuk K-Nearest Neighbors (75.79%) dan Random Forest (77.14%). Hal ini menarik, karena studi komparatif lain seperti oleh Muchtar & Muchtar (2024) pada buah mangga menemukan bahwa KNN (98.75%) justru sedikit lebih unggul dari SVM (97.5%) [14], yang menunjukkan bahwa pilihan model terbaik dapat bervariasi tergantung pada karakteristik dataset buah yang spesifik.

Pencapaian akurasi 81.78% bukanlah sekadar hasil dari penerapan algoritma tunggal, melainkan hasil dari metodologi yang cermat untuk memerangi *overfitting*. Seperti ditunjukkan pada Tabel 4, eksperimen awal (Eksperimen Gagal 2) yang menggunakan parameter kurang ketat menghasilkan akurasi latih 100%, sebuah indikasi jelas dari 'penghafalan' data. Kunci keberhasilan penelitian ini terletak pada dua langkah metodologis utama, yaitu reduksi dimensi agresif menggunakan Principal Component Analysis (PCA) dari 30.000 fitur menjadi 51 komponen utama, serta tuning parameter regularisasi C yang ketat (0.2–0.6) untuk mencapai kondisi *good fit*. Pendekatan ini memungkinkan model mengurangi kompleksitas data dan menekan risiko *overfitting*, yang ditunjukkan oleh selisih akurasi latih dan uji yang relatif rendah (11.04%). Penggunaan PCA untuk reduksi fitur adalah praktik yang tervalidasi; penelitian pada klasifikasi kematangan ceri kopi juga mengimplementasikan PCA untuk mereduksi dimensi data fitur warna sebelum melakukan klasifikasi, yang terbukti efektif meningkatkan efisiensi [15].

Analisis mendalam terhadap hasil rinci memberikan wawasan tentang perilaku model. *Confusion matrix* pada Gambar 3 menunjukkan bahwa tantangan terbesar model adalah membedakan antara kelas 'Matang' dan 'Mentah', di mana 40 sampel 'Matang' salah diklasifikasikan sebagai 'Mentah'. Temuan ini didukung kuat oleh visualisasi PCA pada Gambar 2. Plot PCA menunjukkan bahwa meskipun kelas 'SetengahMatang' (kuning) membentuk klaster yang relatif terpisah, kelas 'Matang' (ungu) dan 'Mentah' (teal) menunjukkan tumpang tindih (*overlap*) yang signifikan. Ini mengindikasikan bahwa fitur warna yang diekstraksi dari kedua kelas tersebut memiliki kemiripan yang tinggi, sehingga menjadi batas keputusan yang paling sulit bagi model SVM. Hal ini juga tercermin pada Tabel 3, di mana kelas 'Mentah' mencatat F1-Score terendah (0.80).

Jika dibandingkan dengan penelitian terkait pada pendahuluan, akurasi 81.78% ini memperkuat temuan sebelumnya tentang efektivitas SVM untuk klasifikasi buah, seperti pada tomat. Meskipun akurasi ini belum setinggi 97% yang dicapai pada lemon, hal ini dapat dipahami mengingat kompleksitas visual nanas. Nanas memiliki perubahan warna yang tidak seragam dan berbintik-bintik (dari hijau, kuning, hingga oranye), yang merupakan masalah klasifikasi yang secara inheren lebih sulit daripada perubahan warna seragam pada lemon. Keterbatasan utama penelitian ini adalah ketergantungan penuh pada fitur warna mentah yang diratakan (30.000 fitur). Penelitian ini tidak menyertakan fitur tekstur (seperti GLCM, yang disebutkan dalam studi tomat) atau fitur bentuk, yang dapat menjadi area perbaikan untuk penelitian di masa depan.

CONCLUSIONS AND RECOMMENDATIONS

Penelitian ini mengusulkan metode klasifikasi tingkat kematangan buah nanas berbasis citra warna menggunakan Support Vector Machine (SVM) yang dipadukan dengan reduksi dimensi Principal Component Analysis (PCA) dan optimasi parameter melalui GridSearchCV. Pendekatan ini merupakan peningkatan dibandingkan metode klasifikasi nanas sebelumnya yang umumnya menggunakan fitur warna secara langsung tanpa reduksi dimensi dan optimasi parameter.

Dibandingkan dengan model klasifikasi nanas tanpa PCA dan GridSearchCV, metode yang diusulkan mampu mengurangi kompleksitas fitur dan menekan *overfitting*, sehingga menghasilkan model yang lebih stabil dan memiliki kemampuan generalisasi yang lebih baik. Dengan demikian,

kombinasi SVM, PCA, dan GridSearchCV terbukti efektif sebagai peningkatan metodologi dalam klasifikasi kematangan nanas berbasis citra warna.

Untuk penelitian selanjutnya, disarankan untuk menggabungkan fitur tambahan selain warna. Penggunaan fitur tekstur (misalnya GLCM, seperti yang disebutkan pada penelitian tomat) atau fitur bentuk dapat dieksplorasi untuk membantu model membedakan dengan lebih baik antara kelas 'Matang' dan 'Mentah' yang tumpang tindih.

Disarankan untuk memperluas dataset penelitian dengan mencakup lebih banyak variasi, seperti kondisi pencahayaan yang berbeda, varietas nanas yang beragam, dan sudut pengambilan gambar yang berbeda, untuk meningkatkan ketahanan dan generalisasi model di dunia nyata.

Sebagai prospek pengembangan, model SVM yang telah divalidasi ini dapat diimplementasikan ke dalam aplikasi *real-time*, seperti aplikasi *smartphone* untuk petani atau diintegrasikan ke dalam sistem penyortir otomatis (*conveyor belt*) untuk pengujian fungsional di lingkungan industri pascapanen.

REFERENCES

- [1] W. O. Mardiana, N. A., & Windari, "Klasifikasi Tingkat Kematangan Buah Nanas Menggunakan Metode Deep Learning," *G-Tech J. Teknol. Terap.*, vol. 8, no. 1, pp. 186–195, 2024.
- [2] Y. Reswan, R. Toyib, H. Witriyono, and A. Anggraini, "Klasifikasi Tingkat Kematangan Buah Nanas Berdasarkan Fitur Warna Menggunakan Metode K-Nearest Neighbor (KNN)," *J. Media Infotama*, vol. 20, no. 1, pp. 280–287, 2024.
- [3] J. G. M. Sanu, "Identifikasi Kematangan Buah Nanas Menggunakan Citra Digital Dengan Metode K-Nearest Neighbor (K-Nn) Dan Support Vector Machine (Svm)," *HOAQ (High Educ. Organ. Arch. Qual. J. Teknol. Inf.)*, vol. 16, no. 1, pp. 35–48, 2025, doi: 10.52972/hoaq.vol16no1.p35-48.
- [4] A. I. Maula, W. A. Triyanto, and P. Setiaji, "Sistem Klasifikasi Kematangan Apel Fuji berdasarkan Warna menggunakan KNN untuk Sortasi Otomatis," *Edumatic J. Pendidik. Inform.*, vol. 9, no. 2, pp. 589–598, 2025, doi: 10.29408/edumatic.v9i2.31243.
- [5] K. Ibutama, M. G. Suryanata, R. O. Putri, and A. Al Hafiz, "Seleksi Tingkat Kematangan Citra Buah Belimbing Menggunakan Ruang Warna CMYK," *J. SAINTIKOM (Jurnal Sains Manaj. Inform. dan Komputer)*, vol. 22, no. 2, p. 302, 2023, doi: 10.53513/jis.v22i2.8356.
- [6] W. O. Mardiana, N. A., & Windari, "Systematic Literature Review : Klasifikasi Tingkat Kematangan Buah Pisang," *J. Teknol. Terap.*, vol. 8, no. 1, pp. 186–195, 2024.
- [7] N. Arifin, C. Nur Insani, and M. R. Rasyid, "Jurnal SAINTIKOM (Jurnal Sains Manajemen Informatika dan Komputer) Klasifikasi Tingkat Kematangan Buah Tomat menggunakan Computer Vision untuk Smart Agriculture," *J. SAINTIKOM (Jurnal Sains Manaj. Inform. dan Komputer)*, vol. 22, no. 2, pp. 509–516, 2023, [Online]. Available: <https://ojs.trigunadharma.ac.id/index.php/jis/index>
- [8] Mualfah, D. Rivaldi, H. Al Amin, and J. Sunanto, "KLASIFIKASI BUAH JERUK LEMON BERDASARKAN TINGKAT KEMATANGAN MENGGUNAKAN METODE SVM DAN NAIVEBAYES," vol. 5, no. 2, pp. 114–121, 2025.
- [9] M. Fajar, M. B. Sulthan, and I. Wahyudi, "Klasifikasi Tingkat Kematangan Buah Tomat Menggunakan Fitur Rgb Dan Hsi Berbasis Backpropagation," *J. Apl. Teknol. Inf. dan Manaj.*, vol. 4, no. 1, pp. 84–95, 2023, doi: 10.31102/jatim.v4i1.2177.
- [10] A. Paliling, M. Muchtar, and F. Fardian, "Sistem Cerdas Deteksi Kematangan Buah Naga Berbasis HSV-KNN," *e-Jurnal JUSITI (Jurnal Sist. Inf. dan Teknol. Informasi)*, vol. 14, no. 1, pp. 46–55, 2025, doi: 10.36774/jusiti.v14i1.1718.
- [11] A. Dwi Rizkika, A. Yudo Husodo, and R. DwiYansaputra, "IMPLEMENTASI METODE CONVOLUTIONAL NEURAL NETWORK DALAM KLASIFIKASI TAHAPAN

-
- KEMATANGAN BUAH MANGGIS (Implementation Of Convolutional Neural Network Method In Classification Of Maturity Stages Of Mangosteen Fruit),” Universitas Mataram, 2024.
- [12] L. C. Fadli Julizar1, “Performance Analysis of SVM and Naïve Bayes for Mango Image Classification Based on Ripeness Level and Variety,” *ComniTech J.*, vol. 2, no. 1, pp. 1–13, 2022, [Online]. Available: <https://journal.unilak.ac.id/index.php/ComniTech/article/view/28163>
- [13] B. Oktaviana and S. Suriati, “Implementation of the Support Vector Machine (SVM) Method for Classifying the Maturity Level of Oil Palm Fruit,” *J. Appl. Informatics Comput.*, vol. 9, no. 5, pp. 2288–2295, 2025, doi: 10.30871/jaic.v9i5.10783.
- [14] M. Muchtar and R. A. Muchtar, “PERBANDINGAN METODE KNN DAN SVM DALAM KLASIFIKASI KEMATANGAN BUAH MANGGA BERDASARKAN CITRA HSV DAN FITUR STATISTIK,” *JITET (Jurnal Inform. dan Tek. Elektro Ter.)*, vol. 12, no. 2, pp. 876–884, 2024.
- [15] A. Wulandari, R. Heriansyah, and L. W. Astuti, “Implementasi Algoritma K-nearest Neighbor dan Principal Component Analysis untuk Klasifikasi Tingkat Kematangan Ceri Kopi Robusta Berdasarkan Warna,” *J. Komputer, Inf. dan Teknol.*, vol. 3, no. 2, pp. 1–9, 2024.