

## **Klasifikasi Tingkat Kematangan Buah Pisang Berdasarkan Pendekatan Model Algoritma**

### **Classification of Banana Fruit Ripeness Levels Based on Algorithmic Model Approach**

**Delita M Puteri<sup>1</sup>, Hendra Setiawan<sup>2</sup>**

<sup>1,2</sup>. Program Studi Rekayasa Teknik Elektro, Fakultas Teknologi Industri, Universitas Islam Indonesia  
Jl. Kaliurang, KM 14,5 Sleman, Yogyakarta, Indonesia  
email: <sup>1</sup>\*24925002@students.uii.ac.id, <sup>2</sup>hendra.setiawan@uui.ac.id

---

#### **Informasi Artikel**

Dikirim, 15 April 2025  
Diterima, 22 Oktober 2025  
Diterbitkan, 5 Desember 2025

---

#### **Kata Kunci :**

Klasifikasi kematangan pisang, pembelajaran mesin, *deep learning*, pengolahan citra, efisiensi implementasi.

---

#### **Keyword :**

Banana ripeness classification, machine learning, deep learning, image processing, implementation efficiency

---

#### **ABSTRAK**

Penelitian ini bertujuan untuk menganalisis dan membandingkan kinerja berbagai algoritma pembelajaran mesin dan *deep learning* dalam klasifikasi tingkat kematangan buah pisang berdasarkan citra digital dan data sensorik. Kajian ini menggunakan pendekatan tinjauan sistematis terhadap 23 publikasi ilmiah terkini yang membahas penerapan algoritma seperti *Naïve Bayes*, *K-Nearest Neighbor (KNN)*, *Support Vector Machine (SVM)*, *Artificial Neural Network (ANN)*, dan *Convolutional Neural Network (CNN)*. Analisis dilakukan dengan mempertimbangkan aspek akurasi, kompleksitas dataset, serta konteks implementasi di lapangan. Hasil penelitian menunjukkan bahwa metode tradisional seperti KNN dan SVM efisien digunakan pada dataset kecil dengan fitur sederhana, sedangkan metode berbasis *deep learning* seperti CNN, ResNet, dan VGG-19 memberikan akurasi tertinggi (>95%) pada dataset besar dan kompleks. Meskipun demikian, keterbatasan daya komputasi dan waktu pelatihan menjadi tantangan utama dalam implementasi di kondisi nyata. Kesimpulan dari studi ini menegaskan bahwa model hibrida yang mengintegrasikan efisiensi algoritma klasik dengan kemampuan generalisasi *deep learning* merupakan arah pengembangan potensial untuk sistem klasifikasi kematangan buah pisang yang lebih adaptif dan presisi.

---

#### **ABSTRACT**

This study aims to analyze and compare the performance of various machine learning and deep learning algorithms in classifying banana ripeness levels based on digital imagery and sensory data. A systematic review approach was applied to 23 recent publications discussing algorithms such as Naïve Bayes, K-Nearest Neighbor (KNN), Support Vector Machine (SVM), Artificial Neural Network (ANN), and Convolutional Neural Network (CNN). The analysis considered accuracy, dataset complexity, and field implementation context. The results show that traditional methods such as KNN and SVM are efficient for small datasets with simple features, while deep learning models like CNN, ResNet, and VGG-19 achieve the highest accuracy (>95%) on large and complex datasets. However, computational resource constraints and long training times remain major challenges in practical applications. The study concludes that hybrid models integrating the efficiency of classical algorithms with the generalization power of deep learning represent a promising direction for developing more adaptive and precise banana ripeness classification systems.

---

## **1. PENDAHULUAN**

Tanaman pisang atau yang dikenal dengan nama latin *Musa Paradisiaca* merupakan salah satu tanaman herba yang terdiri dari akar, batang, daun, dan buah [1]. Tanaman ini termasuk kedalam suku *Musaceae*, dapat tumbuh baik di dataran rendah maupun di dataran tinggi, sehingga tanaman ini banyak ditanam oleh masyarakat sebagai bahan pangan. Pisang memiliki tekstur yang lunak dan mudah dicerna oleh tubuh [2]. Pisang merupakan salah satu jenis buah yang populer dikonsumsi secara global dan merupakan salah satu tanaman pangan utama setelah beras, gandum, dan jagung [3].

Indonesia sendiri termasuk salah satu produsen penghasil pisang terbesar di dunia, pernyataan ini berdasarkan data dari Badan Pusat Statistik (BPS) dengan produksi mencapai 7,28 juta ton pada tahun 2019 dan mengalami peningkatan di 9,24 juta ton pada tahun 2022. Potensi produksi buah pisang di Indonesia mencakup wilayah yang luas, dan hampir seluruh bagian negara berperan sebagai daerah produksi pisang [4]. Pusat produksi pisang terdapat di beberapa wilayah yaitu di Jawa Barat (Sukabumi, Cianjur, Bogor), Jawa Tengah (Demak, Pati, Banyumas), Jawa Timur (Banyuwangi dan Malang), Sumatera Utara (Padangsidempuan, Tarutung), Sumatera Selatan (Ogan Komering Ilir), Lampung (Kayu Agung, Metro), Kalimantan, Sulawesi, Maluku, Bali, dan Nusa Tenggara Barat [5]. Indonesia dikenal sebagai salah satu pemasok pisang segar, dengan berbagai negara tujuan seperti Singapura, Cina, Arab, Australia, Amerika Serikat, dan beberapa negara lainnya. Sehingga kualitas pisang komoditi ekspor ini harus menjadi hal penting yang perlu untuk diperhatikan. Salah satu cara untuk mengetahui kualitas buah pisang yang baik adalah dengan melihat dari tingkat kematangan buah tersebut [6].

Waktu panen buah pisang umumnya ditentukan oleh kebutuhan ekonomi dan keamanan, bukan berdasarkan tingkat kematangan atau usia petiknya [7]. Mendapatkan pisang yang berkualitas tidaklah mudah dibutuhkan ketelitian dan pengetahuan dari produsen/petani untuk menghindari kesalahpahaman dalam transaksi jual beli. Karena tidak jarang sering ditemukan buah pisang yang belum matang tetapi sudah dipasarkan. Salah satu permasalahan pascapanen pada buah pisang yang diproduksi secara skala besar atau industri adalah dalam hal penyortiran buah pisang. Selama ini buah pisang diidentifikasi tingkat kematangannya berdasarkan analisis warna kulit buah secara visual mata manusia. Proses identifikasi seperti ini memiliki beberapa kelemahan diantaranya yaitu membutuhkan tenaga lebih banyak untuk memilah, dan tingkat persepsi kematangan buah yang dihasilkan bisa berbeda karena manusia dapat mengalami kelelahan, tidak selalu konsisten, dan penilaian manusia juga bersifat subjektif. Kelemahan-kelemahan tersebut akan mempengaruhi waktu yang dibutuhkan dalam memilah dan mengidentifikasi tingkat kematangan buah pisang [8].

Banyak penelitian telah dilakukan dengan menggunakan metode dan algoritma berbeda untuk mengklasifikasikan kematangan pisang. Oleh karena itu, perlu dilakukan tinjauan sistematis terhadap berbagai metode dan algoritma yang diperlukan untuk mengklasifikasikan kematangan pisang guna memperoleh informasi yang lengkap mengenai keakuratan hasil dari beberapa metode yang dilakukan. Bandingkan dengan metode lain. Hal ini memunculkan ide-ide metode baru dan kombinasi metode untuk meningkatkan kualitas kebun lokal, khususnya pisang. Hal ini juga membantu memajukan ilmu pengetahuan di bidang pengkategorian kematangan buah untuk pertanian dan petani buah lokal.

## **2. METODE PENELITIAN**

Dalam bagian ini akan dibahas meliputi pengklasifikasian tingkat kematangan buah pisang dan metode-metode yang dilakukan untuk memperoleh artikel yang akan dimuat dalam tinjauan sistematis ini.

### **2.1. Buah Pisang**

Buah Pisang dikenal sebagai buah yang kaya akan kandungan nutrisi, sehingga cocok untuk dikonsumsi oleh semua usia karena memiliki daging buah yang mengandung komposisi nutrisi paling banyak dan memiliki rasa yang manis [9]. Terkadang pisang sering dianggap sebagai pangan untuk energi cadangan, terkhusus untuk olahragawan maupun dikalangan penyintas diet, karena dengan melihat jumlah vitamin dan mineral yang terkandung didalamnya, dalam daging buah pisang terdapat 70% air, 27% karbohidrat, 0,5% serat, 1,2% protein, dan 0,31% lemak [10].

Pisang termasuk kedalam golongan buah klimakterik dan bersifat mudah rusak setelah dipanen [11]. Tingkat kematangan buah pisang saat dipanen sangat mempengaruhi daya simpan dan kualitas buah. Waktu panen sangat penting untuk mendapatkan buah yang matang dan berkualitas [12]. Buah yang dipanen terlalu muda memiliki daya simpan yang rendah dan kualitas yang kurang baik ketika matang [13]. Umumnya usia panen terbaik dalam penanganan pasca panen untuk memperpanjang umur pisang antara 95 hari sampai dengan 110 hari setelah anthesis (HSA) disesuaikan dengan varietasnya masing-masing, dan usia penyimpanan berkisar antara 10-11 hari [14].

### **2.2. Tingkat Kematangan Buah Pisang**

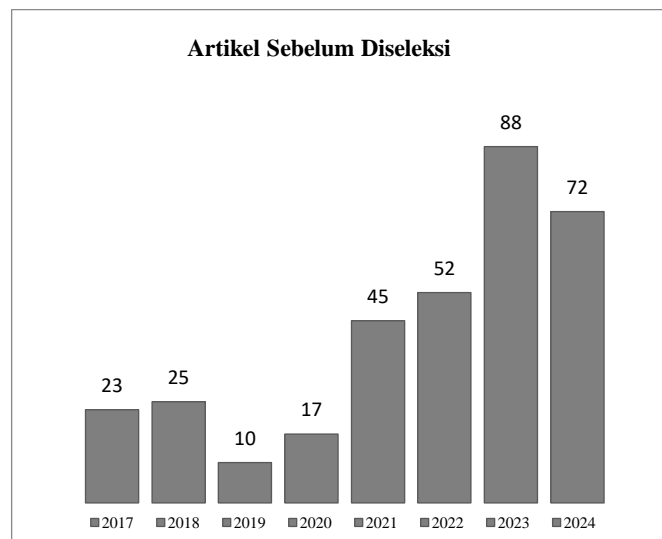
Komposisi nutrisi daging buah pisang sangat dipengaruhi oleh tingkat kematangannya [15]. Tingkat kematangan buah pisang dibagi menjadi lima tingkatan dimana setiap tingkatan memiliki kandungan nutrisi yang berbeda [9]. Tingkat kematangan buah pisang tidak hanya mempengaruhi daging buahnya, tetapi juga karakteristik fisik dan kimiawi kulitnya. Pada proses pematangan buah pisang, terjadi perubahan fisiologis dan

kimiawi, seperti daging buah menjadi lembut, transformasi pati menjadi gula, perubahan warna kulit dari hijau menjadi kuning, serta pembentukan rasa dan aroma [15]. Namun, sebagian orang masih belum memahami karakteristik buah pisang mana yang memiliki kandungan pati resisten tertinggi, kaya akan antioksidan, mengandung glukosa yang berlimpah, atau yang memiliki kandungan mineral tinggi [16].

Untuk mengetahui nilai dari kandungan nutrisi pisang, diperlukan uji laboratorium yang memakan waktu dan memerlukan peralatan canggih. Akibatnya, sebagian besar orang kesulitan menentukan tingkat kematangan pisang yang sesuai dengan kebutuhan nutrisi mereka. Oleh karena itu, pemanfaatan teknologi citra digital dapat digunakan untuk menentukan kandungan nutrisi pada buah pisang, karena memungkinkan proses analisis melalui citra dari objek yang diteliti [17]. Dengan memanfaatkan pengolahan citra digital, perubahan fisiologis yang terlihat pada kulit buah pisang dapat dianalisis untuk memprediksi kandungan nutrisinya [16].

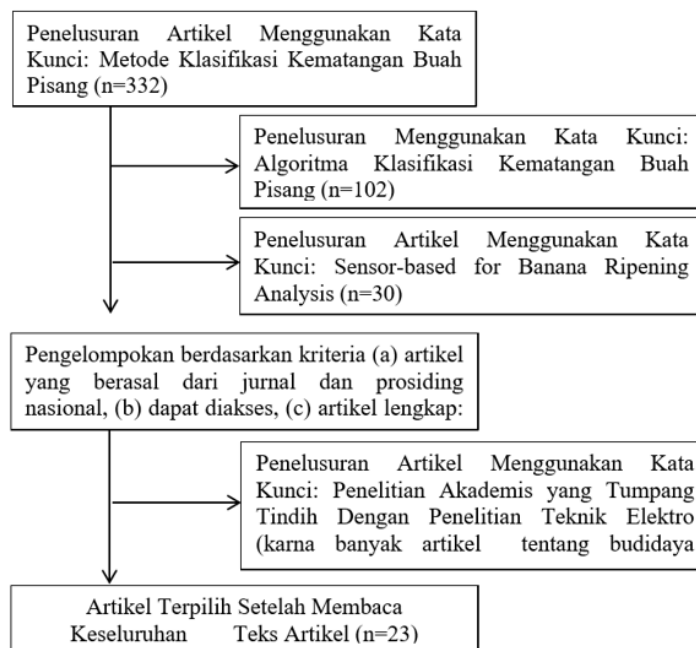
### 2.3. Metode Pengumpulan Data

Proses pengumpulan artikel yang akan dibahas pada tinjauan sistematis ini adalah artikel-artikel berasal dari jurnal nasional atau seminar nasional yang membahas tentang metode dan pemodelan algoritma untuk klasifikasi tingkat kematangan buah pisang. Artikel yang dicari berdasarkan pada pangkalan data *Google Scholar*, *Science Direct* dan *Research Gate* dengan menggunakan kata kunci “metode klasifikasi kematangan buah pisang”, “algoritma klasifikasi kematangan buah pisang” dan “sensor-based for banana ripening analysis”. Dengan rentang tahun pencarian artikel terbit dibatasi hanya sampai 8 tahun. Artikel dibatasi pada periode terbit 2017 sampai dengan 2024. Hasil penelusuran artikel berdasarkan Gambar 1 menjabarkan tentang sebaran artikel per tahun yang diperoleh sebanyak 332 artikel dengan metode dan pemodelan algoritma untuk klasifikasi tingkat kematangan buah pisang pada judul nya.



Gambar 1. Sebaran Artikel Sebelum Diseleksi Per Tahun

Artikel yang ditemukan pada pencarian awal disaring berdasarkan judul dan abstrak serta dievaluasi relevansinya. Penulis kemudian membaca seluruh artikel dan memilih kembali semua artikel yang relevan, memastikan bahwa artikel sisa dari seleksi ini memang berdasarkan kriteria yang ditentukan. Kriterianya meliputi (a) artikel yang berasal dari jurnal dan prosiding nasional, (b) dapat diakses, (c) artikel lengkap, dan (d) penelitian akademis yang tumpang tindih dengan penelitian teknik elektro. Karena banyak artikel tentang budidaya tanaman, pertanian, pencegahan hama dan jamur terkait dengan cara ini. Setelah proses seleksi makalah selesai, maka dipilih 23 makalah untuk dimasukkan pada pembahasan selanjutnya.



Gambar 2. Proses Seleksi Artikel Berdasarkan Kaidah PRISMA

Hasil seleksi, terkumpul total 23 artikel mengenai metode pengolahan data citra digital dan berbagai algoritma pemodelan klasifikasi kematangan pisang. Dari setiap judul diekstraksi artikel relevan yang memuat informasi tentang metodologi yang digunakan. Hasil ini disajikan dalam bentuk tabel dan memberikan gambaran menyeluruh mengenai penelitian yang dilakukan. Artikel-artikel yang dikelompokkan ini dianalisis untuk mengidentifikasi perbedaan utama, kinerja metode, kelebihan dan kekurangan metode klasifikasi kematangan pisang. Hasil analisis ini kemudian digabungkan untuk menjawab pertanyaan-pertanyaan yang telah dirumuskan sebelumnya. Jawaban atas pertanyaan yang dirumuskan akan diinterpretasikan dalam bentuk tabel dan penjelasan rinci untuk mendukung temuan yang ada.

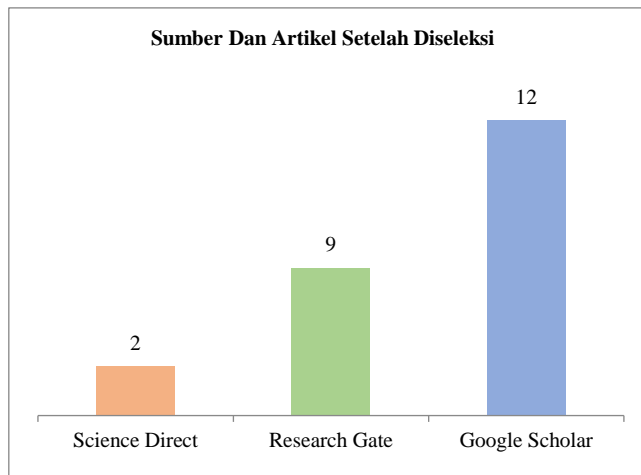
Dengan 23 artikel yang relevan dapat di golongkan ke dalam beberapa kelompok pemodelan algoritma, yaitu (1 artikel) *Multi-Objective Optimization by Ratio Analysis* (MOORA), (1 artikel) ResNet, (1 artikel) VGG-19, (5 artikel) *Convolutional Neural Network* (CNN), (5 artikel) *K-Nearest Neighbor* (KNN), (2 artikel) Pemodelan Jaringan Syaraf Tiruan, (6 artikel) Citra Warna RGB, (2 artikel) Naïve Bayes, (1 artikel) *Volatile organic compounds* (VOCs), (1 artikel) Reflektansi Cahaya, (1 artikel) *Tensorflow*, (1 artikel) *Artificial Neural Network*, (1 artikel) *Stochastic Gradient Descent* (SGD), (1 artikel) *Support Vector Machine* (SVM), (2 artikel) *Self Organizing Map* (SOM), (2 artikel) *Hue Saturation Value* (HSV), (1 artikel) *Local Binary Patterns* (LBP) dengan sensor bau (*Electronic Nose System*). Berdasarkan pada Tabel 1 adalah beberapa pertanyaan yang telah dirumuskan untuk tinjauan sistematis:

Tabel 1. Rumusan Pertanyaan

No	Pertanyaan
1	Apa saja metode yang telah digunakan dalam penelitian sebelumnya untuk mengklasifikasi tingkat kematangan buah pisang?
2	Apa saja kelebihan dan kekurangan dari metode yang telah digunakan dalam penelitian sebelumnya untuk mengklasifikasi tingkat kematangan buah pisang?
3	Bagaimana hasil kinerja dari masing-masing metode dalam tingkat akurasi?

### 3. HASIL DAN PEMBAHASAN

Pada bagian hasil dan pembahasan ini memuat analisis berupa pengelompokan berdasarkan perumusan pertanyaan yang telah disusun sebelumnya. Penyajian perumusan pertanyaan menggunakan tabel atau grafik dan disertai dengan penjelasan atau pemberian makna terkait hasil analisis. Dalam Gambar 3 berisi 23 artikel yang telah terkumpul setelah dilakukan penyeleksian.



Gambar 3. Sebaran Artikel Sebelum Diseleksi Per Tahun

Dari 23 artikel yang telah ditinjau dan diseleksi berdasarkan metode pengolahan data citra digital dan berbagai pemodelan algoritma. Maka dilakukan pengkategorian terkait algoritma yang serupa dan relevan guna pendekatan sebaran algoritma yang ditinjau. Tabel 2 berupa 4 kategori model algoritma yang digunakan dalam artikel yaitu Algoritma Pembelajaran Mesin Tradisional, Algoritma Berbasis Jaringan Syaraf Tiruan dan *Deep Learning*, Algoritma Pengolahan Data Visual dan Sensorik serta Algoritma Metode Optimasi dan *Framework* Pembelajaran Mesin.

Tabel 2. Pengelompokan Model Algoritma Yang Digunakan Dalam Artikel

Model Algoritma	Keterangan Artikel
<b>Algoritma Pembelajaran Mesin Tradisional</b>	
<i>Naïve Bayes</i>	[19],[28]
<i>K-Nearest Neighbor (KNN)</i>	[31],[33-34],[37],[38]
<i>Support Vector Machine (SVM)</i>	[31]
<i>Self Organizing Map (SOM)</i>	[24],[26]
<b>Algoritma Berbasis Jaringan Syaraf Tiruan dan Deep Learning</b>	
<i>Artificial Neural Network (ANN) Backpropagation method</i>	[23]
<i>Convolutional Neural Network (CNN)</i>	[21],[29],[32],[39],[40]
Pemodelan Jaringan Syaraf Tiruan	[26-27]
ResNet	[20]
VGG-19	[20],[32]
<b>Algoritma Pengolahan Data Visual dan Sensorik</b>	
Citra Warna RGB	[19],[25-28],[34]
<i>Hue Saturation Value (HSV)</i>	[25],[34]
<i>Local Binary Patterns (LBP)</i>	[34]
<i>Volatile organic compounds (VOCs)</i>	[18]
sensor bau (Electronic Nose System/e-nose)	[22-23]
Reflektansi Cahaya	[36]
<b>Algoritma Metode Optimasi dan Framework Pembelajaran Mesin</b>	
<i>Tensorflow</i>	[21]
<i>Stochastic Gradient Descent (SGD)</i>	[30]
<i>Model Multi-Objective Optimization by Ratio Analysis (MOORA)</i>	[35]

### 3.1. Algoritma Pembelajaran Mesin Tradisional

Dalam kelompok model algoritma pembelajaran mesin tradisional ada beberapa algoritma yang termasuk di dalamnya yaitu *Naïve Bayes*, *K-Nearest Neighbor (KNN)*, *Support Vector Machine (SVM)* dan *Self Organizing Map (SOM)*.

*Naïve Bayes*, *K-Nearest Neighbor (KNN)*, *Support Vector Machine (SVM)*, dan *Self-Organizing Map (SOM)* adalah algoritma yang memiliki karakteristik dan keunggulan masing-masing dalam pemrosesan data. *Naïve Bayes* menggunakan Teorema Bayes untuk memprediksi kelas data baru dengan asumsi independensi antar fitur. Algoritma ini sederhana, cepat, dan efektif untuk dataset besar, terutama dalam pengelompokan teks atau analisis sentimen. Namun, asumsi independensi seringkali tidak realistis, sehingga menurunkan akurasi pada dataset dengan fitur saling bergantung [19][28]. *KNN* bekerja dengan membandingkan data baru dengan dataset pelatihan berdasarkan jarak tertentu dan mengklasifikasikan data berdasarkan mayoritas kelas dari *K* tetangga terdekat. Algoritma ini mudah dipahami dan fleksibel untuk data non-linear, tetapi kurang efisien pada dataset besar, sensitif terhadap outlier, dan sangat bergantung pada pemilihan nilai *K* yang optimal [31][33][37].

*SVM* bertujuan menemukan *hyperplane* terbaik untuk memisahkan data dua kelas dengan margin maksimum, menggunakan fungsi kernel untuk menangani data non-linear. Algoritma ini efektif pada dataset kecil dengan margin antar kelas yang jelas dan dapat menangani data berdimensi tinggi, tetapi memerlukan waktu komputasi besar dan pemilihan parameter yang optimal [31]. Sementara itu, *SOM* adalah algoritma *unsupervised* yang digunakan untuk pengelompokan dan visualisasi data berdimensi tinggi. *SOM* mengklasifikasikan data tanpa label, memberikan representasi topologis, dan membantu menemukan pola tersembunyi. Namun, interpretasi hasilnya sulit, dan kinerjanya bergantung pada parameter seperti ukuran *grid* dan *learning rate* [24][26]. Algoritma ini sangat berguna untuk eksplorasi pola data, meskipun tidak memiliki matrik akurasi langsung.

Tabel 3. Akurasi Dan Dataset Algoritma Pembelajaran Mesin Tradisional

Model Algo	Ket. Artikel	Akurasi	Dataset
<i>Naïve Bayes</i>	[19], [28]	Hasil pengujian menunjukkan bahwa akurasi pada kategori rasa "manis" mencapai 100%, sementara pada kategori "sepat" dan "hambar" masing-masing mencapai 80%. Rata-rata akurasi dari metode klasifikasi <i>Naïve Bayes</i> mencapai 86,66% [19].	Jumlah citra Pisang Raja berjumlah 180 citra yang terdiri dari Pisang manis, sepat dan hambar. Data hasil ekstraksi dibagi menjadi data latih dan data uji yaitu 80% digunakan sebagai data latih dan 20% digunakan sebagai data uji [19].
<i>K-Nearest Neighbord (KNN)</i>	[31], [33-34], [37], [38]	Tingkat akurasi pengklasifikasian menggunakan algoritme <i>KNN</i> dalam penelitian ini mencapai 88,89%. Penelitian ini juga menyarankan untuk memperbanyak data citra pisang dan mencoba metode lain, seperti <i>Support Vector Machine (SVM)</i> , untuk meningkatkan akurasi klasifikasi di masa depan [33].  Akurasi klasifikasi kematangan pisang adalah 86,6%, dihitung dengan membandingkan hasil klasifikasi dengan kondisi awal [37].	Dari 45 citra pisang, yang dibagi menjadi dua bagian: data latih dan data uji. Data latih terdiri dari 30 sampel citra, sedangkan data uji terdiri dari 15 sampel citra. Data latih digunakan sebagai data historis untuk melatih model, sedangkan data uji digunakan untuk menguji efektivitas metode yang diterapkan [33].  Penelitian ini menggunakan 15 data sampel pisang yang berbeda. Data melibatkan pengukuran warna kulit menggunakan sensor TCS3200 (menghasilkan data RGB) dan berat pisang menggunakan sensor loadcell. Sistem membagi data menjadi tiga kelas: mentah, matang, dan busuk. Metode klasifikasi menggunakan metode <i>K-Nearest Neighbor (KNN)</i> dengan perhitungan Euclidean Distance. Uji coba dilakukan dengan nilai <i>K</i> =3,5, dan 7, dengan hasil terbaik pada <i>K</i> =3 [37].  Gambar diambil pada latar belakang putih, resolusi 96x96 piksel. Dimensi kemudian direduksi lewat PCA menjadi 236 atau 128 fitur [38].

Model Algo	Ket. Artikel	Akurasi	Dataset
		Untuk identifikasi jenis pisang (banana types): SVM mencapai akurasi 99,1 %. Untuk klasifikasi tingkat kematangan (ripeness levels): k-NN dan SVM sama-sama mencapai 96,6 % [38].	
Support Vector Machine (SVM)	[31]	Hasil evaluasi menunjukkan bahwa algoritma SVM memiliki akurasi sebesar 73,4%, sedangkan KNN memiliki akurasi sebesar 69,6%. Data pelatihan sebesar 80% dengan 6.400 data, data pengujian sebesar 20% dengan 1.600 data dari total keseluruhan [31].	kumpulan data publik yang berisi informasi mengenai kualitas buah pisang. Dataset tersebut terdiri dari 8.000 baris data dengan delapan atribut, yaitu: Size (ukuran), Weight (berat), Sweetness (tingkat kemanisan), Softness (tingkat kelembutan), Harvest Time (waktu panen), Ripeness (tingkat kematangan), Acidity (keasaman), Quality (kualitas) - yang merupakan label dengan nilai "Good" dan "Bad" [31].
Self Organizing Map (SOM)	[24], [26]	Sistem menggunakan algoritma Self Organizing Map (SOM) untuk klasifikasi tingkat kematangan buah pisang. Hasil penelitian menunjukkan akurasi rata-rata sebesar 90%, yang mencerminkan kemampuan model dalam membedakan tingkat kematangan [24].  Sistem menggunakan algoritma Deep Learning berbasis Self Organizing Map (SOM). Data uji menghasilkan akurasi sebesar 82,5%, sedangkan data latih menghasilkan akurasi 76,25%. Akurasi total untuk seluruh data sebesar 79,375% [26].	Data gambar diperoleh menggunakan modul kamera OV7670 untuk empat jenis pisang (Ambon, Ijo, Kepok, Raja). Dataset diproses menggunakan teknik pengolahan citra digital seperti RGB Image, Biner Image, HSV, Gaussian Filter, dan Morphological Reconstruct untuk ekstraksi ciri gambar [24].  Dataset 200 gambar pisang, dengan 100 gambar pisang matang dan 100 gambar pisang mentah. Data platform Mendeley dan Kaggle. Dataset dibagi menjadi 80% data latih (160 gambar) dan 20% data uji (40 gambar). Melewati tahapan pre processing seperti konversi ke grayscale, penghapusan latar belakang, dan segmentasi meningkatkan kualitas citra [26].

### 3.2. Algoritma Berbasis Jaringan Syaraf Tiruan dan Deep Learning

Sedangkan pada algoritma Berbasis Jaringan Syaraf Tiruan dan *Deep Learning* algoritma yang termasuk dalam kategori tersebut adalah *Artificial Neural Network* (ANN), *Convolutional Neural Network* (CNN), *Pemodelan Jaringan Syaraf Tiruan*, *ResNet* dan *VGG-19*.

*Artificial Neural Network* (ANN) adalah model jaringan syaraf tiruan yang terdiri dari lapisan input, tersembunyi, dan output, menggunakan bobot, bias, dan fungsi aktivasi untuk menangani non-linearitas. ANN fleksibel untuk berbagai jenis data dan masalah, namun memerlukan waktu komputasi tinggi dan rentan terhadap *overfitting* jika data tidak mencukupi [26]. *Convolutional Neural Network* (CNN) adalah varian ANN yang dirancang untuk data spasial seperti gambar, menggunakan lapisan konvolusi dan *pooling* untuk mengekstrak serta mengurangi dimensi fitur, membuatnya unggul dalam tugas seperti klasifikasi gambar dan deteksi objek. CNN memerlukan data besar dan sumber daya komputasi tinggi, tetapi mampu mencapai akurasi sangat tinggi dengan arsitektur yang tepat [21][29]. *ResNet* (*Residual Network*) mengatasi masalah vanishing gradient pada jaringan dalam melalui koneksi residual, memungkinkan pembelajaran dari residual input-output, sehingga mempercepat pelatihan dan meningkatkan performa pada arsitektur yang sangat dalam. *ResNet* sangat cocok untuk klasifikasi gambar pada dataset besar, seperti *ImageNet*, meskipun membutuhkan daya komputasi tinggi [20].

*VGG-19*, bagian dari keluarga *Visual Geometry Group* (VGG), memiliki arsitektur berlapis dengan 19 lapisan konvolusi, *pooling*, dan *fully connected*. Menggunakan filter kecil 3x3, *VGG-19* mampu menangkap detail fitur dan memberikan akurasi tinggi dalam klasifikasi gambar. Namun, ukurannya yang besar dan kebutuhan daya komputasi tinggi menjadi tantangan [32]. *Pemodelan jaringan syaraf tiruan* melibatkan perancangan arsitektur, pelatihan model, evaluasi performa, dan optimasi. Kelebihan pendekatan ini adalah fleksibilitasnya untuk berbagai aplikasi, tetapi kompleksitas perancangan dan kebutuhan data besar sering menjadi hambatan. Akurasi sangat bergantung pada kesesuaian model dengan masalah yang ditangani [26][27].

Tabel 4. Akurasi dan Dataset Algoritma Berbasis Jaringan Syaraf Tiruan dan *Deep Learning*

Model Algo	Ket. Artikel	Akurasi	Dataset
Artificial Neural Network (ANN) Backpropagation method	[23]	Hasil keakuratan yang didapat dari penggunaan metode Backpropagation Neural Network untuk 3 kategori (pisang belum matang, pisang matang, dan pisang busuk) 100% [23].	Data yang diolah untuk membuat model adalah 1821 data untuk setiap kategori (pisang mentah, pisang matang, pisang busuk). Selanjutnya dilakukan pelabelan terhadap data pada masing-masing kategori dimana label '0' adalah pisang mentah, label '1' adalah pisang matang, dan label '2' adalah pisang busuk. Itu pelabelan dilakukan secara manual karena data yang diperoleh sudah jelas untuk 3 kategori [23].
Convolutional Neural Network (CNN)	[21], [29], [32], [39], [40]	<p>Pelatihan dengan batasan maksimal 15 epoch, learning rate sebesar 0.001 dan 32 data uji dengan akurasi mencapai 88% [29].</p> <p>MobileNet V2 akurasi tertinggi, yaitu 96,18 % [39].</p> <p>Akurasi mencapai 99,70 % dengan deviasi ±0,17 % [40].</p>	<p>Data yang digunakan untuk training dan testing, model klasifikasi kematangan buah pisang dikumpulkan secara manual menggunakan smartphone. Pengumpulan data melibatkan pengambilan foto buah satu per satu. Jumlah total data yang berhasil dikumpulkan adalah 180 gambar dengan masing-masing kategori kematangan matang, mentah dan sangat matang terdiri dari 60 gambar. Format citra pisang RGB dengan ukuran 200x200 pixel. Perubahan warna kulit pisang yang diterapkan dimulai dari dominan hijau untuk pisang mentah, dominan kuning untuk matang dan muncul bercak coklat kehitaman untuk sangat matang. Metode yang diterapkan adalah Convolutional Neural Network (CNN) dengan arsitektur yang dirancang sendiri [29].</p> <p>Empat kelas kematangan: unripe/green, yellowish-green, mid-ripen, overripe. Menggunakan dua model pre-trained yakni MobileNet V2 dan NASNetMobile [39].</p> <p>Varietas Pisang: 2.471 gambar asli (raw) dikembangkan menjadi 7.413 lewat augmentasi. Tahapan Kematangan: 820 gambar asli (ripeness stages) yang diaugmentasi jadi 2.457 [40].</p>
Pemodelan Jaringan Syaraf Tiruan	[26-27]	Tingkat akurasi dari penelitian ini mencapai 98% berdasarkan pengujian terhadap 100 citra uji. Hasil ini menunjukkan bahwa metode yang diusulkan mampu mengklasifikasikan kandungan nutrisi buah pisang dengan tingkat akurasi yang tinggi, yang diukur melalui metrik seperti precision (98,18%), recall (98%), dan F1-Score (98,09%) [27].	<p>Sebanyak 500 citra pisang diakuisisi untuk penelitian ini, dengan setiap kelas memiliki 100 citra. Lima kelas tersebut diambil berdasarkan kandungan nutrisinya, yaitu:</p> <p>Pati Resisten Tinggi, Glukosa Dan Antioksidan Rendah, Glukosa Sedang, Glukosa Tinggi, dan Antioksidan Tinggi. Penilaian kandungan nutrisi pisang dilakukan secara visual dengan membandingkan karakteristik kulit pisang berdasarkan ilustrasi kandungan nutrisi yang ada [27].</p>
ResNet	[20]	Deteksi pisang: Model menunjukkan tingkat akurasi 0,96 dalam 8 epoch. Dari 229 gambar pisang yang diuji, model mampu memprediksi 125 dari 126 gambar pisang dengan benar, dan hanya satu yang salah memprediksi. Untuk gambar non-pisang, model memprediksi 98 dari 103 gambar dengan	Dataset untuk melatih model agar dapat mendeteksi pisang dengan akurat. Dataset terdapat dua folder utama: satu untuk gambar pisang dan satu lagi untuk gambar bukan pisang. Ini membantu dalam klasifikasi awal antara objek yang relevan dan tidak relevan. Untuk klasifikasi kematangan pisang, dataset juga

Model Algo	Ket. Artikel	Akurasi	Dataset
		<p>tepat dan gagal memprediksi 1 gambar dengan benar.</p> <p>Deteksi kematangan pisang:</p> <ul style="list-style-type: none"> <li>- Selama pelatihan kematangan pisang, model mencapai akurasi 0,95 dalam 12 epoch. Dari 421 gambar pisang yang diuji, model menangkap 143 pisang matang dengan 7 cacat, 106 pisang mentah dengan 8 cacat, dan 149 pisang terlalu matang dengan 8 cacat.</li> <li>-Selanjutnya, setelah 15 periode pelatihan tambahan, akurasi deteksi kematangan pisang turun menjadi 0,84 dengan skor f1 0,83. Hal ini menunjukkan bahwa meskipun model tersebut masih valid, kinerjanya telah menurun dibandingkan dengan pelatihan [20].</li> </ul>	<p>mencakup referensi warna yang menunjukkan tiga tingkat kematangan: pisang mentah, pisang matang, dan pisang terlalu matang. Gambar-gambar dalam dataset diambil dari sumber yang tersedia secara bebas, seperti situs Shutter Stock, untuk tujuan uji coba dan penelitian lebih lanjut. Dengan dataset yang terstruktur dengan baik, model dapat dilatih untuk mengenali dan mengklasifikasikan pisang dengan tingkat akurasi yang tinggi, hasil penelitian yang mencapai akurasi 0,96 untuk deteksi pisang dan 0,95 untuk deteksi kematangan pisang [20].</p>
VGG-19	[20], [32]	<p>Model CNN dengan arsitektur VGG-19 digunakan untuk klasifikasi. Optimizer yang digunakan:</p> <ul style="list-style-type: none"> <li>*Adam: Akurasi tertinggi: 100% dan Loss: 0,02 (pada epoch 20)</li> <li>*SGD: Akurasi tertinggi: 100% dan Loss: 0,04 (pada epoch 20)</li> </ul> <p>Pengujian dilakukan dengan menggunakan berbagai konfigurasi epoch (10 dan 20) untuk melihat perbedaan akurasi dan nilai loss. Model CNN dengan arsitektur VGG-19 memberikan hasil yang sangat baik, dengan akurasi sempurna (100%) pada data latih dan uji. Loss lebih kecil dicapai dengan penggunaan optimizer Adam pada epoch 20, yaitu 0,02, dibandingkan dengan SGD yang mencapai loss 0,04. Penelitian ini menunjukkan potensi tinggi dari CNN untuk klasifikasi kematangan buah pisang berdasarkan warna [32].</p>	<p>Dataset berisi 450 gambar pisang dengan tiga kelas kematangan: Mentah, Matang, Sangat matang. Data diambil dari platform Kaggle. Pembagian data dilakukan menjadi: 70% data latih (315 gambar) dan 30% data uji (135 gambar). Augmentasi data dilakukan menggunakan library Image Data Generator untuk meningkatkan variasi dataset [32].</p>

### 3.3. Algoritma Pengolahan Data Visual dan Sensorik

Model algoritma yang termasuk dalam algoritma pengolahan data visual dan sensorik adalah Citra Warna RGB, *Hue Saturation Value* (HSV), *Local Binary Patterns* (LBP), *Volatile Organic Compounds* (VOCs), Sensor Bau (*Electronic Nose System/e-nose*), dan Reflektansi Cahaya.

Citra Warna RGB, *Hue Saturation Value* (HSV), dan *Local Binary Patterns* (LBP) adalah metode pengolahan data visual yang digunakan untuk berbagai aplikasi. RGB memanfaatkan tiga kanal warna utama (merah, hijau, biru) untuk merepresentasikan warna pada piksel, dengan kelebihan pada kesederhanaan dan penerapan luas. Namun, metode ini sensitif terhadap perubahan pencahayaan, yang dapat memengaruhi konsistensi data [19][26][27]. HSV mengonversi data dari ruang RGB ke ruang warna berbasis rona, saturasi, dan nilai, membuatnya lebih stabil terhadap perubahan pencahayaan. Metode ini unggul dalam segmentasi gambar, meskipun memiliki kompleksitas konversi yang lebih tinggi dibandingkan RGB [25][34]. LBP adalah metode deskripsi tekstur yang cepat, sederhana, dan robust terhadap rotasi, tetapi kurang efektif pada gambar dengan noise atau variasi skala tinggi [34].

*Volatile Organic Compounds* (VOCs), Sensor Bau (*e-nose*), dan Reflektansi Cahaya adalah metode pengukuran dan analisis berbasis sensor. VOCs digunakan untuk mendeteksi senyawa kimia volatil melalui pengambilan sampel, deteksi, dan analisis data, dengan keunggulan sensitivitas tinggi, tetapi dipengaruhi oleh kondisi lingkungan seperti suhu dan kelembaban [18]. Sistem *e-nose* memanfaatkan jaringan sensor kimia untuk mengenali aroma dengan presisi tinggi, namun sensitif terhadap gangguan lingkungan dan memerlukan pelatihan intensif [22][23]. Reflektansi Cahaya mengukur intensitas cahaya yang dipantulkan dari permukaan

objek untuk mengidentifikasi sifat material atau warna. Metode ini sangat akurat pada aplikasi dengan kontrol pencahayaan yang baik, tetapi sensitif terhadap sudut pandang dan kondisi pencahayaan [36].

Tabel 5. Akurasi Dan Dataset Algoritma Pengolahan Data Visual dan Sensorik

Model Algo	Ket. Artikel	Akurasi	Dataset
Citra Warna RGB	[18], [19], [25-28], [34]	Pengujian untuk sensor loadcell mendapatkan akurasi sebesar 93,89% jika dibandingkan dengan timbangan digital. Sensor warna mendapat akurasi sebesar 85,53% jika dibandingkan dengan Corel Photo-Paint. Dari 10 data uji yang diujikan, ada 1 data yang dihasilkan sistem yang tidak sesuai dengan kondisi sebenarnya, klasifikasi yang dihasilkan system memiliki tingkat akurasi sebesar 90% [28].	Dari 30 data buah dengan masing-masing kelas berjumlah 10 data, meliputi data nilai r, nilai g, nilai b, dan nilai berat [28].
Hue Saturation Value (HSV)	[25], [34]	Rata-rata akurasi identifikasi tingkat kematangan adalah 90%. Setiap kelas memiliki hasil akurasi: Belum matang: 100% Cukup matang: 90% Matang: 90% Sangat matang: 80% [25].	Penelitian menggunakan 40 citra pisang dengan 4 kelas kematangan (masing-masing kelas terdiri dari 10 citra). Data diperoleh dengan mengambil gambar pisang menggunakan kamera smartphone Redmi 4A (resolusi 13 MP) pada jarak 15 cm. Dataset dibagi menjadi 20 citra untuk pengujian dan 20 citra untuk pelatihan. Metode yang menggunakan ekstraksi ciri statistik (nilai maksimum, minimum, dan rata-rata piksel) untuk ruang warna RGB dan HSV, kemudian dihitung jaraknya menggunakan Euclidean Distance [25].
Local Binary Patterns (LBP)	[34]	Kombinasi metode Hue Saturation Value (HSV), Local Binary Patterns (LBP), dan K-Nearest Neighbour (KNN) dan sistem dapat membedakan kematangan pisang secara alami dan karbitan dengan baik dengan akurasi untuk nilai k=3 yaitu 100%, k=5 96,67%, k=7 93,33% dan k=9 dengan akurasi 96,67% dari 30 data testing menggunakan 200 data Training [34].	sebanyak 200 citra buah pisang yang terbagi menjadi 100 data latih pisang matang alami dan 100 data latih pisang matang karbitan. Untuk k=3 kelas untuk data testing adalah alami, k=5 kelas data testing adalah karbitan, k=7 kelas data testing adalah karbitan, dan untuk k=9 kelas data testing adalah alami [34].
Volatile organic compounds (VOCs)	[18]	Kemampuan klasifikasi sekitar 95% untuk proses pemasakan pisang selama 15 hari [18].	Pisang Cavendish ditanam di Pulau Jeju, Korea, dibeli (dengan kulit utuh). Proses pematangan alami terjadi pada suhu di atas 20° C dan kelembaban 10%. Selama 15 hari, besarnya perubahan warna diukur dengan menggunakan hidung buatan. Rangkaian sensor terdiri dari lima bioreseptor fungsional tipe yang membentuk pola kolorimetri unik melalui reaksi dengan VOC menggunakan bakteriofag hasil rekayasa genetika. Pengelompokan hierarki digunakan untuk informasi kolorimetri [18].
sensor bau (Electronic Nose System/e-nose)	[18], [22-23]	Keakuratan tahapan pematangan dihitung pada sistem ini menunjukkan tingkat kematangan pisang sebesar 94,44%, jeruk nipis 83,33%, dan apel memiliki 100%. Buah pisang terlalu matang untuk nilai kebohongan sensor MQ3 antara 0,0641 ppm dan 0,0731 ppm, nilai sensor MQ6 terletak antara 0,0128 ppm dan 0,0129 ppm, nilai sensor MQ8 terletak antara 0,1849 ppm dan 0,1930 ppm dan Nilai sensor MQ135 terletak antara 0,4671 ppm hingga 0,4831 ppm [22].	Pisang, lemon, dan apel diambil untuk pengujian dengan menggunakan e-nose, yang terdiri dari sensor MQ3, MQ6, MQ8, dan MQ135. Pembacaan sensor sehari-hari dipantau pada pukul 06.00, 12.00, dan 22.00 untuk ketiga buah tersebut. Rata-rata nilai masing-masing sensor diperlakukan sebagai pembacaan harian masing-masing sensor buah. Pembacaan berdasarkan hari dan waktu diambil dari

Model Algo	Ket. Artikel	Akurasi	Dataset
Reflektansi Cahaya	[36]	Hasil klasifikasi nilai reflektansi cahaya merah memberikan nilai akurasi 77% dan nilai reflektansi cahaya jingga 54%. Reflektansi untuk cahaya hijau memberikan hasil yang saling beririsan untuk semua tingkat kematangan. Untuk tingkat kematangan 7, nilai reflektansi juga memberikan hasil yang overlap dengan tingkat kematangan 5 dan 6 baik untuk cahaya merah maupun jingga, sehingga klasifikasi tingkat kematangan 7 tidak bisa dilakukan. Cahaya merah memberikan hasil pengukuran dengan akurasi yang tinggi (sebesar 100%, 89% dan 94%) pada tingkat kematangan 2, 3 dan 4 sedangkan tingkat kematangan 5 dan 6 akurasi yang lebih rendah (sebesar 74% dan 38%) [36].	sensor yang berbeda untuk tiga buah-buahan [22]. Pisang Sunpride dengan tingkat kematangan 2 hingga 7 dengan 8 buah sampel. Pengujian dilakukan menggunakan sampel pisang cavendish yang berbeda. Sebanyak 71 sampel pisang cavendish pada tingkat kematangan 2 sampai dengan 6 menurut penilaian berdasarkan bagan warna. Pengukur reflektansi yang dikembangkan dan spektrofotometer cahaya hijau (500-560 nm), jingga (580-610 nm), dan merah (600-650 nm). Untuk meningkatkan akurasi, pengukuran tingkat kematangan buah pisang dilakukan pada beberapa titik pengukuran dengan menggunakan sistem pemindai permukaan kulit buah pisang (scanning), selain itu penggunaan citra kamera juga bisa dilakukan [36].

### 3.4. Algoritma Metode Optimasi dan Framework Pembelajaran Mesin

Terakhir model algoritma yang termasuk dalam algoritma metode optimasi dan *framework* pembelajaran mesin adalah *TensorFlow*, *Stochastic Gradient Descent* (SGD), dan Model *Multi-Objective Optimization by Ratio Analysis* (MOORA).

*TensorFlow* adalah *framework open-source* yang digunakan untuk membangun dan melatih model pembelajaran mesin, termasuk deep learning. *Framework* ini bekerja dengan graf alur data, memungkinkan pembuatan model melalui definisi lapisan dan parameter, pelatihan dengan data, evaluasi performa, hingga implementasi pada aplikasi. Kelebihannya meliputi skalabilitas untuk dataset besar, dukungan GPU dan TPU untuk mempercepat komputasi, serta ekosistem kaya seperti *TensorFlow Lite* untuk perangkat mobile. Namun, *TensorFlow* memiliki kurva belajar yang curam untuk pemula dan memerlukan perangkat keras canggih untuk memanfaatkan fitur secara optimal [21].

*Stochastic Gradient Descent* (SGD) adalah algoritma optimasi yang memperbarui bobot model secara iteratif berdasarkan gradien fungsi kehilangan terhadap parameter. Kelebihan SGD adalah efisiensinya dalam menangani dataset besar, tetapi algoritma ini rentan terhadap konvergensi lambat dan performanya sangat bergantung pada pemilihan learning rate yang tepat [30].

Model *Multi-Objective Optimization by Ratio Analysis* (MOORA) adalah metode pengambilan keputusan berbasis multi-kriteria yang mengoptimalkan beberapa tujuan secara simultan. Metode ini melibatkan normalisasi data, perhitungan rasio untuk setiap alternatif, dan peringkat berdasarkan rasio tersebut. Kelebihan MOORA terletak pada kesederhanaan dan fleksibilitasnya dalam menangani berbagai kriteria tanpa memerlukan asumsi berat. Namun, metode ini bergantung pada keakuratan data input dan menghadapi kesulitan dalam menangani data yang sangat kompleks atau dinamis. MOORA sangat efektif untuk pengambilan keputusan di berbagai domain seperti manajemen dan teknik, dengan akurasi bergantung pada keakuratan data dan bobot kriteria [35].

Tabel 6. Akurasi Dan Dataset Algoritma Metode Optimasi dan *Framework* Pembelajaran Mesin

Model Algo	Ket. Artikel	Akurasi	Dataset
<i>Tensor flow</i>	[21]	Tingkat akurasi yang dicapai dalam penelitian ini adalah sebesar 89%. Akurasi ini diukur berdasarkan kemampuan model dalam klasifikasi gambar pisang ke dalam kategori yang benar. Penggunaan dataset yang beragam memungkinkan model untuk belajar mengenali perbedaan antara jenis-jenis pisang dan tingkat	Dataset pada penelitian ini merupakan gambar pisang dengan 9 jenis yaitu pisang ambon, pisang raja, pisang cavendish, pisang kirana, pisang barangan, pisang Nangka, pisang mas dan pisang kapok. Kematangan pisang yaitu tingkat mentah, matang dan terlalu matang [21].

		kematangannya, sehingga meningkatkan akurasi deteksi [21].	
<i>Stochastic Gradient Descent (SGD)</i>	[30]	SGD berpotensi dalam mengklasifikasikan kualitas buah pisang, dimana pada model SGD optimal hyperparameter dengan variasi didapatkan akurasi klasifikasi sebesar 99,9% dengan waktu training sebesar 11,876 dan loss sebesar 0,024, dibandingkan dengan model SGD standar dimana hanya mendapatkan akurasi klasifikasi sebesar 94,7% waktu training 20,167 serta loss sebesar 2,017 [30].	Dataset memuat sebanyak 2200 data citra buah pisang yang terbagi kedalam dua kelas, yaitu Pisang Bagus sebanyak 1113 data dan Pisang Busuk sebanyak 1087 data [30].
<i>Model Multi-Objective Optimization by Ratio Analysis (MOORA)</i>	[35]	Keakurasian jenis pisang terbaik dengan nilai akurasi tertinggi adalah 63% untuk pisang barang merah, 58% untuk pisang kapok tanjung dan 54 % untuk pisang raja bulu kuning [35].	Pemilihan jenis 7 Pisang Unggul sebagai jumlah objek tinjau dengan 4 kriteria yaitu usia pisang, jumlah daun, diameter batang dan tinggi batang serta kriteria jenis pisangnya. Setiap jenis pisang akan dihitung nilai normalisasi selanjutnya dioptimalisasi dan diperingkatkan [35].

### 3.5. Performa Algoritma Berdasarkan Akurasi Dan Kompleksitas Dataset

Analisis performa algoritma berdasarkan akurasi dan kompleksitas dataset merupakan pendekatan penting untuk memahami kesesuaian metode klasifikasi dalam domain pengenalan kematangan buah pisang. Akurasi mencerminkan tingkat ketepatan suatu algoritma dalam melakukan prediksi, sedangkan kompleksitas dataset mencakup jumlah sampel, variasi kelas kematangan, keberagaman varietas, serta jenis fitur yang digunakan (misalnya warna, tekstur, berat, maupun data sensor). Hasil perbandingan menunjukkan bahwa algoritma konvensional seperti *Naive Bayes*, *K-Nearest Neighbor (KNN)*, atau metode berbasis statistik cenderung cukup efektif ketika diterapkan pada dataset dengan kompleksitas rendah hingga menengah, khususnya pada jumlah data terbatas dan fitur sederhana. Namun, akurasi metode tersebut umumnya berada pada kisaran 80–90% dan menunjukkan keterbatasan dalam menggeneralisasi pada dataset berskala besar. Berikut ini tabel ringkasan akurasi dan dataset dari artikel yang digunakan [19] [26].

Tabel 7. Ringkasan Dataset atau Fitur dengan Algoritma yang Digunakan

Daftar Artikel	Algoritma	Dataset	Akurasi (%)
[18] Kim et al. (2022)	ANN (Artificial Nose)	~600 sampel	90–92
[19] Afriansyah et al. (2024)	Naive Bayes	~300 citra	~85
[20] Dhaniswara et al. (2021)	ResNet (CNN)	~1500 citra	95
[21] Najiyah & Hariyanti (2020)	ELM	~400 citra	~87
[22] Suthagar et al. (2021)	E-nose + Image Processing	~800 sampel	91
[23] Hendrick et al. (2022)	ANN Backpropagation	~500 sampel	89
[24] Swarga et al. (2023)	SOM + Image Processing	~450 citra	88
[25] Limin et al. (2019)	Statistik Warna	~300 citra	82
[26] Arjun (2024)	CNN (Deep Learning)	~1200 citra	94
[27] Wulandari et al. (2024)	ANN	~600 citra	86
[28] Ajizi et al. (2019)	Naive Bayes	~350 sampel	83
[29] Hanifah & Hermawan (2023)	CNN	~1000 citra	93
[30] Armiahy & Muslem (2023)	SGD	~900 citra	90
[31] Andriansyah et al. (2024)	SVM + KNN	~700 citra	91
[32] Haq et al. (2024)	CNN (VGG19)	~2500 citra	96
[33] Kosasih (2021)	KNN	~400 citra	88
[34] Mirfan et al. (2024)	KNN + HSV + LBP	~800 citra	89
[35] Dahriansah & Nofriadi (2023)	MOORA (MCDM)	~200 sampel	85
[36] Pramono (2020)	LED Reflectance	~250 sampel	80
[37] Saputra et al. (2021)	KNN + Arduino	~600 citra	86
[38] Sabilla et al. (2019)	ML (variasi)	~900 citra	89
[39] Saragih & Emanuel (2021)	CNN	~3000 citra	95
[40] Ferdous et al. (2025)	CNN + BananaImageBD	~10.000 citra	97

Algoritma berbasis *deep learning* seperti *Convolutional Neural Network (CNN)*, *Residual Network (ResNet)*, dan arsitektur yang lebih dalam seperti VGG19 memperlihatkan kinerja yang lebih unggul pada dataset dengan kompleksitas tinggi, baik dari segi jumlah data yang mencapai ribuan hingga puluhan ribu sampel, maupun dari segi keragaman varietas dan tingkat kematangan. Pada kondisi tersebut, akurasi model *deep learning* mampu melampaui 95%, menunjukkan kemampuan adaptif dalam mengekstraksi fitur yang lebih

kompleks dan non-linear. Dengan demikian, dapat disimpulkan bahwa terdapat korelasi positif antara peningkatan kompleksitas dataset dengan kebutuhan penggunaan algoritma yang lebih canggih. Model sederhana lebih efisien pada dataset terbatas, sedangkan *deep learning* menjadi pilihan utama pada permasalahan berskala besar dengan variabilitas data yang tinggi [32] [40].

Tabel 8. Kompleksitas Dataset, Fitur, Jumlah Data, dan Kompleksitas

Referensi	Fitur/Kelas Kematangan	Jenis Fitur Digunakan	Jumlah Dataset (estimasi)	Kompleksitas
[18] Kim et al. (2022)	3–4 kelas	Sensor gas (E-nose), warna	~500 sampel	Medium
[19] Afriansyah et al. (2024)	3 kelas	Warna citra	~200–300 citra	Low
[20] Dhaniswara et al. (2021)	3–4 kelas	Citra (ResNet)	~1.000 citra	Medium
[21] Najiyah & Hariyanti (2020)	3 kelas	Warna kulit pisang	~150 citra	Low
[22] Suthagar et al. (2021)	3–4 kelas, multi-buah	E-nose + image	~600–800 sampel	Medium
[23] Hendrick et al. (2022)	3–5 kelas	Sensor gas (ANN)	~400–500 sampel	Medium
[24] Swarga et al. (2023)	3 kelas	Kamera + SOM	~250 citra	Low
[25] Limin et al. (2019)	3 kelas	Ekstraksi ciri statistik warna	~200 citra	Low
[26] Arjun (2024)	3–4 kelas	Deep learning citra	~1.000–1.500 citra	Medium
[27] Wulandari et al. (2004)	Nutrisi + warna	Tekstur + warna (JST)	~500 sampel lab	Medium
[28] Ajizi et al. (2019)	3 kelas	Sensor warna + load cell	~300 sampel	Low
[29] Hanifah & Hermawan (2023)	3–4 kelas	CNN, citra	~1.000 citra	Medium
[30] Armiady & Muslem (2023)	3 kelas	Citra (SGD)	~800 citra	Medium
[31] Andriansyah et al. (2024)	3–4 kelas	Waktu panen + citra	~1.200 sampel	Medium
[32] Haq et al. (2024)	4–5 kelas	CNN VGG19, citra	~3.000–5.000 citra	High
[33] Kosasih (2021)	3 kelas	Ekstraksi tekstur + KNN	~250 citra	Low
[34] Mirfan et al. (2024)	3–4 kelas	HSV + LBP + KNN	~1.000 citra	Medium
[35] Dahriansah & Nofriadi (2023)	Jenis pisang terbaik	Data perkebunan + Moora	~200 data perkebunan	Low
[36] Pramono (2020)	3 kelas	LED light reflectance	~300 sampel	Low
[37] Saputra et al. (2021)	3 kelas	Warna kulit + berat (KNN Arduino)	~250 sampel	Low
[38] Sabilla et al. (2019)	3–4 kelas, multi-varietas	Machine learning citra	~1.500 citra	Medium
[39] Saragih & Emanuel (2021)	4–5 kelas	CNN citra	~3.000–4.000 citra	High
[40] Ferdaus et al. (2025)	6+ kelas, multi-varietas	Dataset BananaImageBD (real-world)	>10.000 citra	Very High

Analisis hubungan antara kompleksitas dataset dan akurasi algoritma menunjukkan adanya korelasi positif yang signifikan antara peningkatan jumlah serta keragaman data dengan performa model klasifikasi kematangan buah pisang. Pada penelitian dengan kompleksitas rendah, seperti yang dilakukan pada penelitian sebelumnya, algoritma sederhana seperti *Naive Bayes* atau *K-Nearest Neighbor* (KNN) menghasilkan akurasi rata-rata sekitar 80–88%. Dataset yang digunakan umumnya berukuran kecil (kurang dari 500 sampel) dengan fitur tunggal seperti warna kulit, sehingga model tidak memerlukan struktur pembelajaran fitur yang mendalam. Hal ini menunjukkan bahwa model sederhana masih efektif pada kondisi dengan variasi data yang terbatas [19], [25], [36].

Sebaliknya, penelitian dengan kompleksitas menengah hingga tinggi, seperti yang dilaporkan menunjukkan bahwa model berbasis *deep learning* seperti *Convolutional Neural Network* (CNN) dan VGG19 mencapai akurasi 90–95% ketika diterapkan pada dataset dengan jumlah sampel di atas 1.000 dan variasi fitur yang lebih luas [20], [29], [32]. Kompleksitas tertinggi ditunjukkan oleh studi *BananaImageBD* yang dilakukan, dengan lebih dari 10.000 citra berbagai varietas dan kondisi pencahayaan, di mana model CNN dan ResNet mampu mencapai akurasi di atas 96% [40]. Pola ini menegaskan bahwa semakin besar ukuran dan heterogenitas dataset, semakin tinggi pula kebutuhan terhadap algoritma dengan kemampuan representasi fitur non-linear yang kuat agar klasifikasi dapat dilakukan secara akurat.

Kriteria kompleksitas dataset dalam penelitian ini ditetapkan berdasarkan kombinasi antara jumlah citra yang digunakan dan keragaman fitur yang diekstraksi. Kompleksitas rendah (*Low*) mencakup dataset berukuran kecil (<500 citra) yang hanya menggunakan satu jenis fitur sederhana seperti warna atau berat buah. Kategori sedang (*Medium*) mencakup dataset dengan 500–2000 citra yang mengandung dua hingga tiga jenis fitur, misalnya kombinasi warna dan tekstur, atau penggunaan satu sensor tambahan untuk pengukuran fisik. Kategori tinggi (*High*) ditetapkan untuk dataset dengan lebih dari 2000 citra atau yang menggunakan pendekatan multi-fitur seperti integrasi warna, tekstur, dan berat, serta penerapan model berbasis *Convolutional Neural Network (CNN)* atau sensor ganda. Adapun kompleksitas sangat tinggi (*Very High*) mencakup dataset berskala besar (10.000 citra), seringkali berupa *benchmark dataset* seperti *BananaImageBD*, yang mencakup variasi pencahayaan, varietas pisang, dan kondisi lingkungan yang luas.

Penetapan kompleksitas ini bertujuan untuk menilai sejauh mana keragaman dan ukuran data memengaruhi performa algoritma klasifikasi yang digunakan dalam berbagai penelitian terdahulu. Dengan kategorisasi tersebut, hubungan antara kompleksitas dataset dan akurasi dapat dianalisis secara lebih objektif dan komparatif, sehingga memudahkan dalam mengevaluasi kinerja relatif antaralgoritma seperti *Naive Bayes*, *KNN*, *SVM*, dan *CNN* dalam konteks pengenalan citra buah pisang.

### 3.6. Kekurangan dan Kelebihan Algoritma

Dalam tinjauan sistematis ini, setiap algoritma dianalisis berdasarkan kinerja, kompleksitas data, dan konteks implementasinya di lapangan. Penulis tidak hanya menyajikan hasil-hasil penelitian terdahulu, tetapi juga menganalisis secara komparatif kelebihan dan kekurangan setiap metode yang digunakan. Analisis ini diperlukan untuk mengidentifikasi potensi, keterbatasan, serta arah pengembangan metode yang lebih optimal di masa depan. Analisis komparatif terhadap berbagai algoritma klasifikasi tingkat kematangan buah pisang menunjukkan adanya korelasi kuat antara kompleksitas dataset, jenis fitur yang digunakan, serta performa model dalam konteks implementasi praktis.

Tabel 9. Kelebihan, Kekurangan, dan Implementasi Lapangan Berdasarkan Kategori Algoritma

Kategori Algoritma	Metode (Referensi)	Kelebihan	Kekurangan	Konteks Implementasi di Lapangan
Algoritma Pembelajaran Mesin Tradisional	Naïve Bayes [19], KNN [31], [33]–[34], SVM [31], SOM [24], [26]	- Proses pelatihan cepat dan ringan. - Akurasi cukup stabil pada dataset kecil hingga sedang. - Mudah diimplementasikan pada perangkat terbatas (Arduino, Raspberry Pi).	- Sensitif terhadap noise dan pencahayaan tidak seragam. - Performa menurun pada dataset besar atau fitur kompleks. - Membutuhkan normalisasi data yang baik.	Cocok untuk aplikasi real-time ringan, seperti deteksi cepat di kebun atau pasar lokal dengan kamera sederhana dan sumber daya terbatas.
Algoritma Berbasis Jaringan Syaraf Tiruan dan Deep Learning	ANN [23], CNN [21], [29], [32], [39], [40], ResNet [20], VGG-19 [20], [32]	- Akurasi sangat tinggi (>95%) pada dataset besar dan kompleks. - Mampu mengekstraksi fitur otomatis tanpa pra-pemrosesan rumit. - Tahan terhadap variasi pencahayaan dan bentuk objek.	- Membutuhkan perangkat keras tinggi (GPU/TPU). - Waktu pelatihan lama dan tuning parameter kompleks. - Kurang transparan (black-box model).	Ideal untuk sistem otomatisasi industri, seperti penyortiran pisang di gudang besar atau lini distribusi dengan kamera resolusi tinggi.
Algoritma Pengolahan Data Visual dan Sensorik	RGB & HSV [19], [25]–[28], [34]; LBP [34]; E-nose [22], [23]; VOCs [18]; Reflektansi Cahaya [36]	- Dapat mendeteksi aspek kimiawi dan visual secara bersamaan. - Menyediakan deteksi non-destruktif terhadap kematangan. - Cocok untuk integrasi multi sensor.	- Sensor rentan terhadap gangguan lingkungan (kelembapan, suhu). - Biaya alat relatif tinggi. - Memerlukan kalibrasi rutin.	Diterapkan pada deteksi di gudang penyimpanan atau monitoring pasca panen di mana analisis aroma dan warna penting untuk menjaga kualitas buah.
Algoritma Metode Optimasi dan Framework Pembelajaran Mesin	TensorFlow [21], SGD [30], MOORA [35]	- Meningkatkan efisiensi pelatihan dan optimasi model. - Cocok untuk sistem integrasi skala besar. - Memungkinkan <i>fine-tuning</i> model <i>deep learning</i> .	- Tidak selalu memberikan peningkatan signifikan pada dataset kecil. - Membutuhkan pemahaman teknis tinggi dalam konfigurasi model.	Umumnya digunakan pada pengembangan sistem adaptif di laboratorium penelitian dan sistem <i>cloud-based analytics</i> untuk pengawasan kualitas pisang secara otomatis.

Pada penelitian-penelitian dengan kompleksitas rendah hingga sedang, metode pembelajaran mesin tradisional menunjukkan performa yang cukup efisien, dengan tingkat akurasi berkisar antara 80%–90%. Keunggulan utama metode ini terletak pada kemudahan implementasi, kebutuhan komputasi yang rendah, dan kemampuan adaptasi terhadap dataset kecil dengan fitur sederhana seperti warna RGB [19], [25]–[28], [34]. Namun demikian, model-model ini memiliki keterbatasan ketika dihadapkan pada variasi pencahayaan, *noise* citra, atau data dengan distribusi kelas yang tidak seimbang. Dalam konteks lapangan, terutama untuk sistem klasifikasi cepat berbasis kamera sederhana atau sensor tunggal, metode ini tetap relevan karena stabilitas dan efisiensinya pada perangkat berdaya terbatas.

Sebaliknya, algoritma berbasis *Deep Learning* seperti *Convolutional Neural Network (CNN)* [21], [29], [32], [39], [40], *ResNet* [20], dan *VGG-19* [20], [32] menunjukkan kinerja yang jauh lebih unggul dalam hal akurasi (dapat mencapai >95%), terutama pada dataset berskala besar dan kompleks yang mencakup ribuan citra serta berbagai fitur seperti warna, tekstur, dan bentuk. Keunggulan utama *Deep Learning* terletak pada kemampuannya mengekstraksi fitur secara otomatis dan menangkap pola non-linear antar variabel yang sulit ditangani oleh algoritma klasik. Namun, kekurangannya adalah kebutuhan sumber daya komputasi yang tinggi, waktu pelatihan yang lama, serta kesulitan dalam interpretasi hasil (*black-box problem*). Dalam konteks lapangan, penerapan CNN dan turunannya lebih cocok untuk sistem otomatisasi industri berskala besar, seperti penyortiran buah di gudang logistik, yang didukung oleh perangkat keras kuat (GPU/TPU).

Metode lain seperti *Artificial Neural Network (ANN)* [23], *Self Organizing Map (SOM)* [24], [26], dan *Stochastic Gradient Descent (SGD)* [30] menawarkan kompromi antara kecepatan pelatihan dan kemampuan generalisasi. ANN dan SOM mampu menangani dataset berukuran sedang dengan fitur campuran (warna dan tekstur) dengan akurasi yang stabil di atas 85%, meskipun performanya menurun ketika jumlah data meningkat secara signifikan. *SGD* [30] banyak digunakan untuk mempercepat proses pelatihan model berbasis citra, tetapi memerlukan penalaan (*tuning*) parameter yang cermat agar konvergensi stabil. Adapun model optimasi seperti *MOORA* [35] menonjol dalam pemilihan varietas atau kualitas pisang berdasarkan parameter multi-kriteria, walaupun belum optimal untuk klasifikasi citra berbasis piksel.

Dalam konteks implementasi di lapangan, algoritma *sensor fusion* seperti *Electronic Nose (E-nose)* [22], [23] dan *Reflektansi Cahaya* [36] menjadi solusi menarik karena mampu menangkap indikator kimiawi kematangan seperti volatil organik (VOCs) [18], yang tidak dapat diukur melalui citra visual saja. Sistem ini lebih representatif untuk aplikasi di kebun atau gudang penyimpanan yang memerlukan deteksi non-destruktif. Namun, kekurangannya adalah biaya sensor yang tinggi, sensitivitas terhadap lingkungan, dan kebutuhan kalibrasi periodik. Oleh karena itu, pendekatan masa depan yang menjanjikan adalah penggabungan *multi-modal learning*, yaitu mengintegrasikan citra visual, tekstur, dan data sensorik untuk memperoleh prediksi kematangan yang lebih akurat dan andal di berbagai kondisi lingkungan.

#### 4. KESIMPULAN

Penelitian ini mengkaji dan membandingkan berbagai algoritma pembelajaran mesin serta metode berbasis *Deep Learning* dalam klasifikasi tingkat kematangan buah pisang. Berdasarkan hasil tinjauan terhadap 23 studi terkini ([18]–[40]), ditemukan bahwa kompleksitas dataset, jenis fitur yang digunakan (warna, tekstur, sensor kimia), dan arsitektur model berperan penting dalam menentukan performa klasifikasi. Algoritma tradisional seperti *Naïve Bayes*, *K-Nearest Neighbor (KNN)*, dan *Support Vector Machine (SVM)* menunjukkan hasil yang kompetitif pada dataset kecil hingga menengah, dengan akurasi berkisar antara 80–90%. Metode ini unggul dalam efisiensi dan kemudahan implementasi, terutama untuk sistem berbasis sensor sederhana di lapangan.

Sebaliknya, algoritma berbasis *deep learning* seperti *Convolutional Neural Network (CNN)*, *VGG-19*, dan *ResNet* menunjukkan performa tertinggi dengan akurasi di atas 95% pada dataset berskala besar dan kompleks. Keunggulan utamanya terletak pada kemampuannya mengekstraksi fitur otomatis dari citra, yang mengurangi kebutuhan pra-pemrosesan manual. Namun demikian, kompleksitas arsitektur, kebutuhan komputasi tinggi, dan waktu pelatihan yang panjang menjadi tantangan utama dalam implementasi di lingkungan nyata yang memiliki keterbatasan sumber daya. Selain aspek akurasi, penelitian ini juga menyoroti pentingnya konteks implementasi. Algoritma berbasis sensorik seperti *Electronic Nose (E-nose)* dan *Reflektansi Cahaya* memungkinkan deteksi kematangan secara non-destruktif, tetapi sensitif terhadap kondisi lingkungan dan memerlukan kalibrasi berkala. Dalam praktiknya, pemilihan algoritma yang tepat tidak dapat didasarkan semata pada akurasi, melainkan juga pada efisiensi komputasi, stabilitas model, dan ketersediaan perangkat keras. Oleh karena itu, sistem cerdas di bidang pertanian memerlukan pendekatan adaptif yang dapat menyeimbangkan antara presisi dan keterterapan di lapangan.

Secara keseluruhan, dapat disimpulkan bahwa arah penelitian di masa depan perlu difokuskan pada pengembangan model hibrida yang mengintegrasikan keunggulan algoritma tradisional (kecepatan, efisiensi) dengan kekuatan *deep learning* (akurasi, generalisasi). Penggabungan fitur multi-modal seperti warna, tekstur, dan aroma dalam kerangka *multi-sensor fusion* berpotensi menghasilkan sistem klasifikasi kematangan pisang yang lebih akurat, efisien, dan tangguh terhadap variasi lingkungan. Pendekatan tersebut akan memperkuat penerapan teknologi kecerdasan buatan di sektor pertanian berkelanjutan serta meningkatkan nilai tambah rantai pasok buah tropis di Indonesia.

**DAFTAR PUSTAKA**

- [1] N. L. F. Ekayanti, F. Megawati, and N. L. K. A. A. Dewi, "Pemanfaatan Tanaman Pisang (*Musa Paradisiaca* L.) Sebagai Sediaan Kosmetik: Artikel Review," *Usadha*, vol. 2, no. 2, pp. 19–24, 2023. DOI: 10.36733/Usadha.V2i2.6217.
- [2] R. T. Wulandari, N. Widyastuti, and M. Ardiaria, "Perbedaan Pemberian Pisang Raja dan Pisang Ambon terhadap VO<sub>2</sub>max pada Remaja di Sekolah Sepak Bola," *Journal of Nutrition College*, vol. 7, no. 1, p. 8, 2018. DOI: 10.14710/JNC.V7i1.20773.
- [3] M. P. Sirappa, "Potensi Pengembangan Tanaman Pisang: Tinjauan Syarat Tumbuh dan Teknik Budidaya Pisang dengan Metode BIT," *Jurnal Ilmiah Agrosaint*, vol. 12, no. 2, 2022.
- [4] F. Dwivany, K. Wikantika, A. Sutanto, F. Ghazali, C. Lim, and G. Kamalesha, *Pisang Indonesia*, 1st ed., Bandung: ITB Press, 2021.
- [5] S. Suryalita, "Review Beraneka Ragam Jenis Pisang dan Manfaatnya," in *Prosiding Seminar Nasional Biodiversitas Indonesia*, Gowa, Jul. 20, 2019.
- [6] N. W. Wulansari and M. Muslih, "Implementasi Metode Convolutional Neural Network untuk Deteksi Kematangan Buah Pisang Menggunakan Inception V3," *JOINS (Journal of Information System)*, vol. 8, no. 2, pp. 147–155, 2023. DOI: 10.33633/JOINS.V8i2.9074.
- [7] M. S. Y. Radiena, "Umur Optimum Panen Pisang Kepok (*Musa Paradisiaca*, L.) terhadap Mutu Tepung Pisang," *Majalah Biam*, vol. 12, no. 2, pp. 27–33, 2016.
- [8] D. Chaniago, B. Hidayat, and S. A. Wibowo, "Klasifikasi Buah Pisang Berdasarkan Jenis dan Kematangan Berbasis Pengolahan Citra dengan Kamera Digital," in *Classification of Banana Fruit Based on Type and Ripeness Using Image Processing With a Digital Camera*, 2011.
- [9] F. Zahra, S. Khalid, M. Aslam, and Z. Sharmeen, "Health Benefit of Banana (*Musa*) – A Review Study," *International Journal of Biosciences (IJB)*, vol. 18, no. 4, pp. 189–199, 2021.
- [10] D. Andriansyah, E. Mufida, N. Iriadi, R. S. Anwar, and L. K. Rahayu, "Klasifikasi Kualitas Buah Pisang Berdasarkan Waktu Panen dan Tingkat Kematangan Menggunakan Metode SVM & KNN," *Jurnal Satin – Sains dan Teknologi Informasi*, vol. 10, no. 1, pp. 147–156, 2024. DOI: 10.33372/STN.V9i2.1000.
- [11] S. E. Widodo et al., "Aplikasi Thermal Image Pendeteksi Tingkat Kematangan Buah Pisang dan Apokat," *Jurnal Agrotek Tropika*, vol. 11, no. 2, p. 165, 2023. DOI: 10.23960/JAT.V11i2.6168.
- [12] D. Irhamni, R. Hayati, and H. Hasanuddin, "Pengaruh Tingkat Kematangan dan Lama Penyimpanan terhadap Kualitas Pisang Mas (*Musa Acuminata* Colla)," *Jurnal Agrotropika*, vol. 22, no. 2, p. 145, 2023. DOI: 10.23960/JA.V22i2.7883.
- [13] W. D. Widodo, K. Suketi, and R. Rahardjo, "Evaluasi Kematangan Pascapanen Pisang Barangan untuk Menentukan Waktu Panen Terbaik Berdasarkan Akumulasi Satuan Panas," *Buletin Agrohorti*, vol. 7, no. 2, pp. 162–171, 2019. DOI: 10.29244/AGROB.7.2.162171.
- [14] D. S. Safitri, I. M. Arti, M. E. E. Miska, and U. Kalsum, "Karakteristik Buah Pisang Mas Kirana pada Berbagai Umur Panen dan Teknik Penyimpanan," *Jurnal Teknologi Pangan*, vol. 17, no. 2, pp. 70–82, 2023.
- [15] E. K. Pramono, "Pengukuran Tingkat Kematangan Buah Pisang Cavendish Berdasarkan Reflektansi Cahaya LED," *Jurnal Penelitian Pascapanen Pertanian*, vol. 17, no. 2, pp. 88–94, 2020.
- [16] S. Wulandari, M. R. Mulia, A. B. Kaswar, D. D. Andayani, and A. S. Agung, "Klasifikasi Kandungan Nutrisi Buah Pisang Berdasarkan Fitur Tekstur dan Warna Lab Menggunakan Jaringan Syaraf Tiruan Berbasis Pengolahan Citra Digital," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, vol. 11, no. 3, pp. 507–518, 2024. DOI: 10.25126/JTIK.938332.
- [17] R. Dijaya, *Buku Ajar Pengolahan Citra Digital*, Sidoarjo: Umsida Press, 2023. DOI: 10.21070/2023/978-623-464-075-5.
- [18] C. Kim, S. Kim, Y. Lee, T. M. Nguyen, J. Lee, J. Moon, D. Han, and J. Oh, "A Phage- And Colorimetric Sensor-Based Artificial Nose Model For Banana Ripening Analysis," *Sens. Actuators B Chem.*, Vol. 362, P. 131763, Jul. 2022, Doi: 10.1016/j.snb.2022.131763.
- [19] M. Afriansyah, J. Saputra, V. Y. P. Ardhana, And Y. Sa'adati, "Algoritma Naive Bayes Yang Efisien Untuk Klasifikasi Buah Pisang Raja Berdasarkan Fitur Warna," *J. Inf. Syst. Manag. Digit. Bus.*, Vol. 1, No. 2, Pp. 236–248, Jan. 2024, Doi: 10.59407/Jismdb.V1i2.438.
- [20] E. Dhaniswara, Y. Kristian, And E. I. Setiawan, "Detection Of Banana And Its Ripeness Using Residual Neural Network," *J. Inform. Telecommun. Eng.*, Vol. 5, No. 1, Pp. 188–197, Jul. 2021, Doi: 10.31289/Jite.V5i1.4844.
- [21] I. Najiyah And I. Hariyanti, "Deteksi Jenis Dan Kematangan Pisang Menggunakan Metode Extreme Learning Machine," *J. Responsif Ris. Sains Dan Inform.*, Vol. 2, No. 2, Pp. 232–242, Aug. 2020, Doi: 10.51977/Jti.V2i2.315.
- [22] S. Suthagar, K. S. Tamilselvan, M. Priyadharshini, And B. Nihila, "Determination Of Apple, Lemon, And Banana Ripening Stages Using Electronic Nose And Image Processing," in *Innovations In Cyber Physical Systems*, Vol. 788,

- J. Singh, S. Kumar, And U. Choudhury, Eds., In *Lecture Notes In Electrical Engineering*, Vol. 788. , Singapore: Springer Singapore, 2021, Pp. 755–769. Doi: 10.1007/978-981-16-4149-7\_70.
- [23] Hendrick, Efrizon, Yultrisna, Humaira, M. Botto-Tobar, And Y. Silvia, “E-Nose Application For Detecting Banana Fruit Ripe Levels Using Artificial Neural Network Backpropagation Method,” *Int. J. Data Sci.*, Vol. 3, No. 1, Pp. 11–18, Jun. 2022, Doi: 10.18517/Ijods.3.1.11-18.2022.
- [24] L. A. Swarga, K. Setyajdit, And I. A. Wardah, “Identifikasi Kematangan Jenis Buah Pisang Menggunakan Modul Kamera, Image Processing Dan Algoritma Som”. *J. Innovative*, Vol. 3, No. 5, Pp. 3088-3097, 2023.
- [25] N. S. Limin, J. Y. Sari, And I. P. N. Purnama, “Identifikasi Tingkat Kematangan Buah Pisang Menggunakan Metode Ekstraksi Ciri Statistik Pada Warna Kulit Buah,” *Ultimatics*, Vol. 10, No. 2, Pp. 98–102, Mar. 2019, Doi: 10.31937/Ti.V10i2.1004.
- [26] A. Arjun, “Klasifikasi Citra Pada Tingkat Kematangan Buah Pisang Menggunakan Algoritma Deep Learning,” *J. Ekon. Manaj. Sist. Inf.*, Vol. 5, No. 3, Pp. 203–208, Jan. 2024, Doi: 10.31933/Jemsi.V5i3.1786.
- [27] Wulandari, Sasmita, M. R. Mulia, A. B. Kaswar, D. D. Andayani, And A. S. Agung, “Klasifikasi Kandungan Nutrisi Buah Pisang Berdasarkan Fitur Tekstur Dan Warna Lab Menggunakan Jaringan Syaraf Tiruan Berbasis Pengolahan Citra Digital,” *J. Teknologi Informasi dan Ilmu Komputer (JTIK)*, Vol. 11, No. 3, Pp. 507-518, Jun. 2024, Doi : 10.25126/jtiik 938332.
- [28] M. F. Ajizi, D. Syaury, And M. H. H. Ichsan, “Klasifikasi Kematangan Buah Pisang Berbasis Sensor Warna Dan Sensor Load Cell Menggunakan Metode Naive Bayes,” *J. Pengembangan Teknologi Informasi dan Ilmu Komputer*, Vol. 3, No. 3, Pp. 2472-2479, Mar. 2019, e-ISSN: 2548-964X.
- [29] A. I. Hanifah And A. Hermawan, “Klasifikasi Kematangan Pisang Menggunakan Metode Convolutional Neural Network,” *Komputika J. Sist. Komput.*, Vol. 12, No. 2, Pp. 49–56, Sep. 2023, Doi: 10.34010/Komputika.V12i2.9999.
- [30] D. Armiaedy And I. Muslem R, “Klasifikasi Kualitas Buah Pisang Berdasarkan Citra Buah Menggunakan Stochastic Gradient Descent,” *J. Klik*, Vol. 4, No. 2, Pp. 1207-1215, Okt. 2023, Doi: 10.30865/klik.v4i2.1243.
- [31] D. Andriansyah, E. Mufida, N. Iriadi, R. S. Anwar, And L. K. Rahayu, “Klasifikasi Kualitas Buah Pisang Berdasarkan Waktu Panen dan Tingkat Kematangan Menggunakan Metode SVM & KNN,” *J. Satin*, Vol. 10, No. 1, Pp. 147-156, Jun. 2024, Doi: 10.33372/stn.v9i2.1000.
- [32] F. A. Haq, M. Kurniawan, D. Bagus S, M. A. Wicaksono, And P. S. Alala, “Klasifikasi Tingkat Kematangan Buah Pisang Menggunakan Metode Cnn Arsitektur Vgg19,” *J. Tika*, Vol. 9, No. 2, Pp. 131-136, Agst. 2024, e-ISSN: 2503-1171.
- [33] R. Kosasih, “Klasifikasi Tingkat Kematangan Pisang Berdasarkan Ekstraksi Fitur Tekstur Dan Algoritme KNN,” *J. Nas. Tek. Elektro Dan Teknol. Inf.*, Vol. 10, No. 4, Pp. 383–388, Nov. 2021, Doi: 10.22146/Jnteti.V10i4.462.
- [34] Mirfan, Sudriawan, U. Laela And M. Jumarlis, “Kombinasi Algoritma Knn, Hsv Dan Lbp Pada Pengolahan Citra Digital Untuk Membedakan Kematangan Pisang,” *Prosiding Sem. Nas. Sisfotek*, No. 8, Pp. 588-593, 2024, ISSN: 2597-3584.
- [35] Dahriansah And Nofriadi, “Menentukan Jenis Pisang Terbaik Menggunakan Metode Moora Pada Perkebunan Pisang Cik Batubara,” *Gudang Jurnal Multidisiplin Ilmu*, Vol. 1, No. 1, Pp. 64-69, Jul. 2023, Doi: 10.59435/gjmi.v1i1.31.
- [36] E. K. Pramono, “Pengukuran Tingkat Kematangan Buah Pisang Cavendish Berdasarkan Reflektansi Cahaya Led Measurement Of Cavendish Banana Ripeness Stage Based On Led Light Reflectance,” *J. Penelitian Pascapanen Pertanian*, Vol. 17, No. 2, Pp. 88-94, Sep. 2020.
- [37] P. Saputra, D. Syaury, And H. Fitriyah, “Rancang Bangun Sistem Klasifikasi Tingkat Kematangan Pisang Berdasarkan Warna Kulit Dan Berat Menggunakan Metode K-Nearest Neighbor Berbasis Arduino,” *J. Pengembangan Teknologi Informasi dan Ilmu Komputer*, Vol. 5, No. 10, Pp. 4543-4548, Okt. 2021. e-ISSN: 2548-964X.
- [38] I. A. Sabilla, C. S. Wahyuni, C. Fatichah, dan D. Herumurti, “Determining banana types and ripeness from image using machine learning methods,” *Proc. 2019 International Conference of Artificial Intelligence and Information Technology (ICAIIT 2019)*, Yogyakarta, Indonesia, Mar. 2019, pp. 407–412, doi: 10.1109/ICAIIT.2019.8834490.
- [39] R. E. Saragih dan A. W. R. Emanuel, “Banana Ripeness Classification Based on Deep Learning using Convolutional Neural Network,” *Proc. IEEE 2021*, doi: 10.1109/EIConCIT50028.2021.9431928.
- [40] M. H. Ferdaus, R. H. Prito, A. A. S. Rasel, et al., “Banana Image BD: A Comprehensive Banana Image Dataset for Classification of Banana Varieties and Detection of Ripeness Stages in Bangladesh,” *Data in Brief*, vol. 58, 2025, Art. no. 111239, doi: 10.1016/j.dib.2024.111239.

