



Department of Digital Business

**Journal of Artificial Intelligence and Digital Business (RIGGS)**

Homepage: <https://journal.ilmudata.co.id/index.php/RIGGS>

Vol. 5 No. 2 (2026) pp: 17921- 17930

P-ISSN: 2963-9298, e-ISSN: 2963-914X

---

## Analisis Perbandingan Algoritma Artificial Neural Network, Logistic Regression, dan Random Forest Menggunakan Fitur SqueezeNet untuk Klasifikasi Kematangan Buah Jeruk Nipis

Robi Aziz Zuama<sup>1</sup>, Arina Selawati<sup>2</sup>

<sup>1,2</sup> Informatika, Fakultas Teknik & Informatika, Universitas Bina Sarana Informatika

<sup>1</sup>[robi.rbz@bsi.ac.id](mailto:robi.rbz@bsi.ac.id) , <sup>2</sup>[arina.asq@bsi.ac.id](mailto:arina.asq@bsi.ac.id)

### Abstrak

Kematangan buah jeruk nipis merupakan faktor penting yang memengaruhi kualitas dan nilai jual produk. Penentuan tingkat kematangan secara manual masih bergantung pada pengamatan visual sehingga berpotensi menimbulkan subjektivitas dan ketidakonsistenan. Penelitian ini bertujuan untuk menganalisis kinerja algoritma Artificial Neural Network (ANN), Logistic Regression (LR), dan Random Forest (RF) dalam mengklasifikasikan tingkat kematangan buah jeruk nipis menggunakan fitur hasil ekstraksi SqueezeNet. Dataset yang digunakan terdiri dari 104 citra buah jeruk nipis yang terbagi secara seimbang menjadi dua kelas, yaitu 52 citra buah matang dan 52 citra buah mentah. Seluruh citra diproses melalui tahap cropping dan resize menjadi 227 × 227 piksel, kemudian dilakukan ekstraksi fitur menggunakan model SqueezeNet pada aplikasi Orange Data Mining. Evaluasi model dilakukan menggunakan metode 10-Fold Cross Validation dengan metrik Accuracy, Precision, Recall, F1-Score, Area Under Curve (AUC), dan Confusion Matrix. Hasil penelitian menunjukkan bahwa Artificial Neural Network memberikan performa terbaik dengan nilai Accuracy sebesar 95,2%, Precision sebesar 95,3%, Recall sebesar 95,2%, F1-Score sebesar 95,2%, dan AUC sebesar 0,997. Logistic Regression memperoleh akurasi sebesar 94,2%, sedangkan Random Forest sebesar 87,5%. Hasil tersebut menunjukkan bahwa kombinasi SqueezeNet sebagai metode ekstraksi fitur dan Artificial Neural Network sebagai algoritma klasifikasi mampu memberikan performa terbaik dalam mengidentifikasi tingkat kematangan buah jeruk nipis.

**Kata Kunci:** Klasifikasi Kematangan Buah, Jeruk Nipis, SqueezeNet, Artificial Neural Network, Machine Learning.

### 1. Latar Belakang

Jeruk (*Citrus spp.*) salah satu komoditas hortikultura yang memiliki nilai ekonomi tinggi, kualitas buah jeruk menjadi faktor utama yang menentukan daya saing produk di pasar domestik maupun internasional. Salah satu indikator kualitas yang paling penting adalah tingkat kematangan buah karena berpengaruh terhadap warna, rasa, aroma, tekstur, kandungan nutrisi, umur simpan, dan penerimaan konsumen. Oleh karena itu, penentuan tingkat kematangan yang akurat menjadi tahapan penting dalam proses panen, sortasi, distribusi, dan pemasaran buah [1], [2], [3].

Seiring meningkatnya permintaan terhadap buah berkualitas tinggi, proses sortasi yang cepat dan akurat menjadi kebutuhan utama dalam sistem pertanian modern. Penentuan tingkat kematangan yang tepat tidak hanya meningkatkan kualitas produk yang dipasarkan, tetapi juga berkontribusi dalam mengurangi kehilangan pascapanen, meningkatkan efisiensi rantai pasok, serta mendukung penerapan smart agriculture. Berbagai penelitian menunjukkan bahwa otomatisasi proses klasifikasi kematangan buah mampu meningkatkan produktivitas, konsistensi hasil sortasi, dan efisiensi operasional dibandingkan metode konvensional yang masih mengandalkan penilaian visual oleh manusia [4], [5], [6].

Pada praktiknya, proses identifikasi tingkat kematangan buah jeruk di tingkat petani maupun industri pascapanen masih didominasi oleh pengamatan visual berdasarkan perubahan warna kulit buah. Metode ini relatif mudah diterapkan, tetapi sangat bergantung pada pengalaman operator sehingga bersifat subjektif dan rentan terhadap inkonsistensi akibat perbedaan persepsi manusia, kondisi pencahayaan, kelelahan, maupun jumlah buah yang harus disortir dalam waktu singkat. Kesalahan dalam proses sortasi dapat menyebabkan buah dipanen sebelum matang atau terlambat dipanen sehingga menurunkan kualitas produk, mempercepat kerusakan selama penyimpanan, mengurangi umur simpan, dan berdampak pada kerugian ekonomi bagi petani maupun pelaku industri hortikultura [1], [2], [3].

---

Analisis Perbandingan Algoritma Artificial Neural Network, Logistic Regression, dan Random Forest Menggunakan Fitur SqueezeNet untuk Klasifikasi Kematangan Buah Jeruk Nipis

Berbagai penelitian di Indonesia juga menunjukkan bahwa metode klasifikasi konvensional berbasis ekstraksi fitur warna RGB [7], [8], HSV [9], maupun HSI masih memiliki keterbatasan ketika dihadapkan pada variasi pencahayaan, latar belakang citra, dan kondisi permukaan buah yang beragam. Meskipun beberapa metode berbasis machine learning seperti Naïve Bayes, Support Vector Machine (SVM) [10], dan K-Nearest Neighbor (KNN) [11] telah menghasilkan akurasi yang cukup baik, performanya masih sangat dipengaruhi oleh kualitas fitur yang diekstraksi secara manual sehingga kemampuan generalisasinya terhadap data baru relatif terbatas.

Dalam beberapa tahun terakhir, pendekatan deep learning, khususnya Convolutional Neural Network (CNN), menjadi metode yang paling banyak digunakan dalam klasifikasi citra buah karena mampu mempelajari representasi fitur secara otomatis tanpa memerlukan proses ekstraksi fitur manual [12]. Berbagai penelitian melaporkan bahwa CNN seperti [1] menyatakan bahwa metode berbasis CNN dan deep learning mendominasi penelitian klasifikasi kematangan buah karena mampu mempelajari fitur visual secara otomatis [2] memanfaatkan deep image features untuk penilaian kualitas berbagai jenis buah dan memperoleh akurasi di atas 97% pada beberapa dataset. Sementara itu, [5], [13] mengembangkan model YOLOv5 ringan untuk deteksi tingkat kematangan blueberry yang mampu mencapai mAP<sub>ghos</sub> 91,5% dengan kecepatan deteksi tinggi, sedangkan [14] menunjukkan bahwa model hibrida Vision Transformer–SENet mampu meningkatkan akurasi klasifikasi buah tomat hingga 99,87% pada data pelatihan. memberikan akurasi yang lebih tinggi dibandingkan metode machine learning konvensional pada klasifikasi tingkat kematangan maupun kualitas buah. Selain CNN, perkembangan arsitektur modern seperti Vision Transformer (ViT) dan model hibrida berbasis perhatian (attention mechanism) juga menunjukkan peningkatan performa dalam pengenalan citra buah dengan karakteristik visual yang kompleks (Yadav et al., 2024).

Meskipun model Convolutional Neural Network (CNN) mampu menghasilkan performa klasifikasi yang tinggi, penerapannya secara langsung (end-to-end) masih menghadapi beberapa tantangan, seperti kebutuhan dataset berukuran besar, waktu pelatihan yang lama, serta kompleksitas komputasi yang tinggi. Untuk mengatasi permasalahan tersebut, pendekatan transfer learning menjadi salah satu solusi yang banyak digunakan karena memanfaatkan model yang telah dilatih pada dataset berskala besar untuk mengekstraksi fitur visual yang lebih representatif. Pendekatan ini terbukti mampu meningkatkan akurasi klasifikasi sekaligus mengurangi waktu pelatihan, terutama pada penelitian dengan jumlah dataset yang terbatas [3], [6], [14].

Salah satu model lightweight CNN yang banyak digunakan dalam transfer learning adalah SqueezeNet, yang dirancang untuk menghasilkan ukuran model yang kecil dengan jumlah parameter yang jauh lebih sedikit dibandingkan arsitektur CNN konvensional tanpa mengurangi kemampuan dalam mengekstraksi fitur visual [15]. Karakteristik tersebut menjadikan SqueezeNet sesuai untuk aplikasi klasifikasi citra pada perangkat dengan sumber daya komputasi terbatas maupun sistem pertanian cerdas (smart agriculture). Selain itu, penggunaan deep feature extraction memungkinkan fitur yang dihasilkan SqueezeNet dimanfaatkan oleh berbagai algoritma machine learning sehingga dapat meningkatkan efisiensi komputasi dan fleksibilitas dalam proses klasifikasi [2], [5].


Berdasarkan hasil telaah literatur, sebagian besar penelitian terdahulu masih berfokus pada penggunaan satu algoritma klasifikasi, baik machine learning maupun deep learning, sehingga belum memberikan gambaran mengenai performa berbagai algoritma klasifikasi terhadap fitur hasil ekstraksi CNN. Selain itu, penelitian pada klasifikasi kematangan buah jeruk umumnya masih menggunakan ekstraksi fitur warna secara manual atau menerapkan CNN sebagai model klasifikasi secara langsung (end-to-end). Penelitian yang memanfaatkan SqueezeNet sebagai deep feature extractor kemudian membandingkan performa beberapa algoritma klasifikasi, seperti Artificial Neural Network (ANN), Logistic Regression (LR) [16], dan Random Forest (RF) pada klasifikasi tingkat kematangan buah jeruk masih sangat terbatas, khususnya pada objek jeruk nipis. Kondisi tersebut menunjukkan masih adanya peluang untuk mengembangkan model klasifikasi yang lebih efisien, ringan, dan memiliki kemampuan generalisasi yang lebih baik.

## 2. Metode Penelitian

Penelitian ini menggunakan pendekatan kuantitatif eksperimental untuk mengevaluasi performa beberapa algoritma machine learning dalam mengklasifikasikan tingkat kematangan buah jeruk berdasarkan fitur yang diekstraksi menggunakan model SqueezeNet. Pendekatan yang diusulkan menggabungkan transfer learning sebagai proses ekstraksi fitur (deep feature extraction) dengan algoritma klasifikasi Artificial Neural Network (ANN), Logistic Regression (LR), dan Random Forest (RF). Pendekatan hibrida ini dipilih karena mampu memanfaatkan representasi fitur yang dihasilkan CNN tanpa harus melatih jaringan secara penuh (end-to-end), sehingga lebih efisien pada dataset berukuran terbatas namun tetap menghasilkan performa klasifikasi yang tinggi.

## 2.1. Tahapan Penelitian

Penelitian dilaksanakan melalui enam tahapan utama, yaitu (1) pengumpulan dataset, (2) pra-pemrosesan citra, (3) ekstraksi fitur menggunakan SqueezeNet, (4) pelatihan model klasifikasi, (5) pengujian model, dan (6) evaluasi kinerja. Alur penelitian ditunjukkan pada Gambar 1.



Gambar 1. Tahapan Penelitian

## 2.2. Dataset

Dataset yang digunakan pada penelitian ini merupakan dataset primer yang diperoleh melalui proses pengambilan gambar secara langsung terhadap buah jeruk nipis menggunakan kamera iPhone 11. Pengambilan citra dilakukan pada lingkungan indoor dengan pencahayaan yang relatif konstan untuk meminimalkan variasi intensitas cahaya selama proses akuisisi. Setiap buah diletakkan di atas latar belakang berwarna putih sehingga objek lebih mudah dipisahkan dari latar belakang dan karakteristik visual buah dapat ditangkap secara optimal.

Dataset terdiri dari 104 citra, yang terbagi menjadi dua kelas, yaitu 52 citra buah mentah dan 52 citra buah matang. Penentuan label kelas dilakukan berdasarkan kondisi fisik buah, terutama perubahan warna kulit yang menjadi indikator tingkat kematangan. Tabel 1 menunjukkan distribusi dataset yang digunakan.

Tabel 1. Distribusi Dataset

| Kelas         | Jumlah Citra |
|---------------|--------------|
| <b>Mentah</b> | 52           |
| <b>Matang</b> | 52           |
| <b>Total</b>  | <b>104</b>   |

Distribusi data yang seimbang bertujuan mengurangi potensi class imbalance sehingga proses pelatihan model dapat berlangsung lebih objektif.

## 2.3. Preprocessing Citra

Tahap preprocessing dilakukan untuk menyeragamkan karakteristik citra sebelum memasuki proses ekstraksi fitur. Tahapan ini terdiri atas:

- Cropping, yaitu memotong bagian citra yang tidak diperlukan sehingga objek jeruk menjadi fokus utama analisis.
- Resize, yaitu mengubah ukuran seluruh citra menjadi  $227 \times 227$  piksel sesuai ukuran input yang digunakan oleh model SqueezeNet.

Melalui tahap ini seluruh citra memiliki dimensi yang seragam sehingga proses ekstraksi fitur dapat dilakukan secara konsisten.

## 2.4. Ekstraksi Fitur Menggunakan SqueezeNet

Ekstraksi fitur dilakukan menggunakan widget Image Embedding pada perangkat lunak Orange Data Mining dengan model SqueezeNet. Pada penelitian ini, SqueezeNet tidak digunakan sebagai model klasifikasi secara langsung (end-to-end), melainkan sebagai deep feature extractor [17].

Transfer learning memungkinkan model memanfaatkan bobot hasil pelatihan sebelumnya pada dataset berskala besar sehingga mampu menghasilkan representasi fitur visual yang lebih informatif dibandingkan ekstraksi fitur warna secara manual.

Output dari proses ini berupa vektor fitur (feature vector) berdimensi tinggi yang merepresentasikan karakteristik visual buah jeruk, seperti warna, tekstur, bentuk, dan pola permukaan. Selanjutnya, vektor fitur tersebut digunakan sebagai masukan bagi algoritma klasifikasi.

## 2.5. Algoritma Klasifikasi

Penelitian ini membandingkan tiga algoritma klasifikasi yang memiliki karakteristik berbeda untuk mengetahui model yang memberikan performa terbaik terhadap fitur hasil ekstraksi SqueezeNet.

### i. Artificial Neural Network (ANN)

Artificial Neural Network merupakan algoritma yang meniru cara kerja jaringan saraf biologis melalui kumpulan neuron yang saling terhubung. ANN mampu mempelajari hubungan nonlinier antar fitur sehingga banyak digunakan pada berbagai permasalahan klasifikasi citra. Pada penelitian ini, parameter ANN menggunakan parameter bawaan (default) dari Orange Data Mining.

Persamaan dasar neuron pada ANN dituliskan sebagai:

$$z = \sum_{i=1}^n w_i x_i + b$$

Kemudian nilai tersebut dilewatkan ke fungsi aktivasi sigmoid:

$$y = \sigma(z) = \frac{1}{1 + e^{-z}}$$

dengan:

$x_i$  = fitur masukan

$w_i$  = bobot

$b$  = bias

$z$  = kombinasi linier

$y$  = keluar neuron

### ii. Logistic Regression

Logistic Regression merupakan algoritma klasifikasi berbasis probabilitas yang digunakan untuk memprediksi peluang suatu data termasuk ke dalam kelas tertentu. Berbeda dengan regresi linier, Logistic Regression menggunakan fungsi sigmoid untuk mengubah nilai linier menjadi probabilitas dengan rentang 0–1. Pada penelitian ini, Logistic Regression digunakan untuk mengklasifikasikan fitur hasil ekstraksi SqueezeNet ke dalam dua kelas, yaitu mentah dan matang. Seluruh parameter model menggunakan konfigurasi bawaan dari Orange Data Mining. Persamaan Logistic Regression dituliskan sebagai berikut.

$$P(y = 1|x) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n)}}$$

### iii. Random Forest

Random Forest merupakan metode ensemble learning yang membangun sejumlah Decision Tree secara acak (bootstrap aggregating atau bagging) [18]. Setiap pohon menghasilkan prediksi secara independen, kemudian hasil akhir ditentukan menggunakan mekanisme majority voting. Pendekatan ini mampu meningkatkan kemampuan generalisasi model sekaligus mengurangi risiko overfitting.

Pada penelitian ini, Random Forest memanfaatkan fitur hasil ekstraksi SqueezeNet sebagai data masukan. Seluruh parameter menggunakan konfigurasi bawaan Orange Data Mining. Prediksi akhir Random Forest diperoleh melalui mekanisme voting mayoritas sebagai berikut.

$$\hat{y} = \text{operatorname{mode}}\{T_1(x), T_2(x), \dots, T_K(x)\}$$

Probabilitas kelas pada Random Forest dapat dihitung menggunakan rata-rata probabilitas dari seluruh pohon.

$$P(y = c|x) = \frac{1}{K} \sum_{i=1}^K P_i(y = c|x)$$

## 2.6. Validasi Model

Evaluasi model dilakukan menggunakan metode 10-Fold Cross Validation. Pada metode ini, dataset dibagi menjadi sepuluh bagian (fold) dengan ukuran yang relatif sama. Pada setiap iterasi, sembilan fold digunakan sebagai data pelatihan sedangkan satu fold digunakan sebagai data pengujian. Proses tersebut dilakukan sebanyak sepuluh kali sehingga setiap data memperoleh kesempatan menjadi data uji satu kali.

Metode 10-fold cross validation dipilih karena mampu menghasilkan estimasi performa model yang lebih stabil dibandingkan pembagian data tunggal (hold-out validation), terutama pada dataset dengan jumlah sampel yang relatif terbatas.

## 2.7. Evaluasi Performa

Masing-masing algoritma dievaluasi menggunakan beberapa metrik evaluasi, yaitu Accuracy, Precision, Recall, F1-Score, Receiver Operating Characteristic (ROC), Area Under Curve (AUC), serta Confusion Matrix. aluasi Performa Model. Accuracy mengukur proporsi prediksi yang benar terhadap seluruh data pengujian.

Accuracy mengukur proporsi prediksi yang benar terhadap seluruh data pengujian.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$$

Precision menunjukkan tingkat ketepatan model dalam memprediksi kelas positif.

$$\text{Precision} = \frac{TP}{TP + FP}$$

Recall mengukur kemampuan model dalam mengenali seluruh data positif.

$$\text{Recall} = \frac{TP}{TP + FN}$$

F1-Score merupakan rata-rata harmonik antara Precision dan Recall.

$$\text{F1-score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

Keterangan:

TP = True Positive

TN = True Negative

FP = False Positive

FN = False Negative

Selain metrik numerik, penelitian ini juga menggunakan Confusion Matrix untuk menganalisis distribusi prediksi benar dan salah pada setiap kelas, serta ROC Curve dan AUC untuk mengevaluasi kemampuan diskriminatif masing-masing model klasifikasi. Alur kerja keseluruhan di Orange Data Mining mengintegrasikan pra-pemrosesan gambar, ekstraksi fitur mendalam, klasifikasi, dan evaluasi ke dalam satu alur visual tunggal, memungkinkan eksperimen yang efisien dan analisis yang dapat direproduksi..

## 3. Hasil dan Diskusi


### 3.1. Gambaran Dataset

Dataset yang digunakan dalam penelitian ini merupakan dataset primer yang diperoleh melalui proses akuisisi citra buah jeruk nipis menggunakan kamera iPhone 11 pada kondisi indoor dengan latar belakang berwarna putih. Dataset terdiri dari 104 citra, yang terbagi menjadi dua kategori, yaitu 52 citra buah matang dan 52 citra buah mentah. Seluruh citra telah melalui tahap cropping dan resize menjadi  $227 \times 227$  piksel sebelum dilakukan proses ekstraksi fitur menggunakan model SqueezeNet.

DOI: <https://doi.org/10.31004/riggs.v5i2.12732>

Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)


Berdasarkan Gambar 3.1, jumlah citra pada kedua kelas memiliki distribusi yang seimbang, yaitu masing-masing sebanyak 52 citra. Keseimbangan dataset ini penting untuk meminimalkan potensi class imbalance yang dapat menyebabkan bias pada proses pelatihan model klasifikasi. Dengan distribusi data yang proporsional, setiap algoritma memperoleh kesempatan yang sama dalam mempelajari karakteristik kedua kelas sehingga hasil evaluasi menjadi lebih objektif.



Gambar 2. distribusi jumlah citra pada masing-masing kelas.

### 3.2. Visualisasi Multidimensional Scaling (MDS)

Setelah proses ekstraksi fitur menggunakan SqueezeNet, dilakukan visualisasi data menggunakan metode Multidimensional Scaling (MDS). MDS digunakan untuk memproyeksikan data berdimensi tinggi ke dalam ruang dua dimensi sehingga hubungan antar sampel dapat diamati secara visual.



Gambar 3. Visualisasi MDS Hasil Ekstraksi Fitur SqueezeNet

Berdasarkan Gambar 3, sebagian besar data telah membentuk dua kelompok (cluster) yang merepresentasikan kelas matang dan mentah. Meskipun demikian, masih terdapat beberapa titik yang saling bertumpang tindih (overlap) di antara kedua kelas serta beberapa outlier yang berada di luar kelompok utama. Kondisi tersebut menunjukkan bahwa fitur hasil ekstraksi SqueezeNet telah mampu menangkap karakteristik visual buah jeruk dengan cukup baik, namun masih terdapat beberapa sampel yang memiliki kemiripan karakteristik sehingga berpotensi menyebabkan kesalahan klasifikasi.

### 3.3. Hasil Evaluasi Model Klasifikasi

Evaluasi performa model dilakukan untuk mengetahui kemampuan masing-masing algoritma dalam mengklasifikasikan tingkat kematangan buah jeruk nipis berdasarkan fitur hasil ekstraksi SqueezeNet. Pengujian menggunakan metode 10-Fold Cross Validation dengan metrik evaluasi meliputi Area Under Curve (AUC), Accuracy (CA), Precision, Recall, F1-Score, dan Matthews Correlation Coefficient (MCC).

Tabel 2. Hasil Evaluasi Model Klasifikasi

| Model                     | AUC   | Accuracy | Precision | Recall | F1-Score | MCC   |
|---------------------------|-------|----------|-----------|--------|----------|-------|
| Artificial Neural Network | 0.997 | 0.952    | 0.953     | 0.952  | 0.952    | 0.905 |
| Logistic Regression       | 0.984 | 0.942    | 0.945     | 0.942  | 0.942    | 0.887 |
| Random Forest             | 0.923 | 0.875    | 0.875     | 0.875  | 0.875    | 0.750 |

DOI: <https://doi.org/10.31004/riggs.v5i2.12732>

Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

Berdasarkan Tabel 3.2, Artificial Neural Network (ANN) memperoleh performa terbaik dibandingkan algoritma lainnya dengan nilai Accuracy sebesar 95,2%, Precision sebesar 95,3%, Recall sebesar 95,2%, F1-Score sebesar 95,2%, serta AUC sebesar 0,997. Nilai AUC yang mendekati 1 menunjukkan bahwa ANN memiliki kemampuan yang sangat baik dalam membedakan citra buah matang dan mentah. Selain itu, nilai MCC sebesar 0,905 mengindikasikan bahwa hasil klasifikasi memiliki tingkat korelasi yang sangat kuat antara prediksi model dan kelas sebenarnya.

Algoritma Logistic Regression menempati urutan kedua dengan nilai Accuracy sebesar 94,2% dan AUC sebesar 0,984. Hasil tersebut menunjukkan bahwa Logistic Regression mampu mengklasifikasikan fitur hasil ekstraksi SqueezeNet dengan tingkat akurasi yang tinggi. Selisih performa yang relatif kecil dibandingkan ANN mengindikasikan bahwa fitur yang dihasilkan SqueezeNet telah memiliki tingkat keterpisahan (separability) yang baik sehingga masih dapat dimodelkan menggunakan klasifikasi linier.

Sementara itu, Random Forest menghasilkan nilai Accuracy sebesar 87,5% dengan AUC sebesar 0,923, yang merupakan performa terendah di antara ketiga algoritma. Walaupun nilai AUC masih termasuk kategori sangat baik ( $>0,90$ ), Random Forest menunjukkan penurunan pada seluruh metrik evaluasi dibandingkan ANN dan Logistic Regression. Hal ini mengindikasikan bahwa mekanisme pembentukan pohon keputusan pada Random Forest belum mampu memanfaatkan representasi fitur berdimensi tinggi hasil ekstraksi SqueezeNet secara optimal.

Secara keseluruhan, hasil evaluasi menunjukkan bahwa penggunaan deep feature extraction melalui SqueezeNet mampu menghasilkan representasi fitur yang efektif untuk klasifikasi tingkat kematangan buah jeruk nipis. Dari ketiga algoritma yang diuji, Artificial Neural Network memberikan performa terbaik pada seluruh metrik evaluasi, sehingga dapat dianggap sebagai model yang paling sesuai untuk proses klasifikasi pada penelitian ini.

### 3.4. Analisis Confusion Matrix

Confusion Matrix digunakan untuk menganalisis kemampuan setiap algoritma dalam mengklasifikasikan citra buah jeruk nipis ke dalam kelas matang dan mentah. Analisis ini menunjukkan jumlah prediksi yang benar maupun salah pada masing-masing kelas sehingga dapat diketahui pola kesalahan klasifikasi yang dihasilkan oleh setiap model.

#### 1. Artificial Neural Network (ANN)



Gambar 4. Hasil Confusion Matrix ANN

Berdasarkan gambar 4, model Artificial Neural Network berhasil mengklasifikasikan 48 dari 52 citra buah matang dan 51 dari 52 citra buah mentah dengan benar. Hanya terdapat 5 kesalahan klasifikasi, sehingga menunjukkan bahwa ANN memiliki kemampuan yang sangat baik dalam membedakan kedua kelas.


#### 2. Logistic Regression

Berdasarkan gambar 5 model Logistic Regression mampu mengklasifikasikan 47 citra matang dan 51 citra mentah secara benar. Total kesalahan klasifikasi sebanyak 6 citra, yang menunjukkan bahwa performa Logistic Regression masih sangat baik meskipun sedikit lebih rendah dibandingkan ANN.



Gambar 5. Hasil Confusion Matrix Logistic Regression

### 3. Random Forest




Gambar 6. Confusion Matrix Random Forest

Berdasarkan gambar 6 hasil Confusion Matrix menunjukkan bahwa Random Forest menghasilkan jumlah kesalahan klasifikasi paling tinggi dibandingkan dua algoritma lainnya. Model ini berhasil mengklasifikasikan 46 citra matang dan 45 citra mentah dengan benar, sedangkan 13 citra mengalami kesalahan prediksi. Hasil ini sejalan dengan nilai Accuracy dan AUC yang lebih rendah dibandingkan ANN dan Logistic Regression.

### 3.5. Analisis ROC Curve

Kurva Receiver Operating Characteristic (ROC) digunakan untuk mengevaluasi kemampuan model dalam membedakan dua kelas, yaitu buah jeruk nipis matang dan mentah. Semakin mendekati sudut kiri atas kurva ROC dan semakin besar nilai Area Under Curve (AUC), maka semakin baik kemampuan model dalam melakukan klasifikasi.



Gambar 7. Kurva ROC Hasil Evaluasi Model (a) Mentah (b) Matang

DOI: <https://doi.org/10.31004/riggs.v5i2.12732>

Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

Berdasarkan Gambar 7, algoritma Artificial Neural Network (ANN) menghasilkan nilai AUC sebesar 0,997, yang menunjukkan kemampuan diskriminasi hampir sempurna dalam membedakan kedua kelas. Logistic Regression memperoleh nilai AUC sebesar 0,984, yang juga termasuk kategori sangat baik dengan kurva ROC yang mendekati ANN. Sementara itu, Random Forest menghasilkan nilai AUC sebesar 0,923, yang masih menunjukkan performa klasifikasi yang baik, namun berada di bawah dua algoritma lainnya. Secara keseluruhan, hasil analisis ROC Curve memperkuat hasil evaluasi pada subbab sebelumnya bahwa Artificial Neural Network merupakan algoritma dengan kemampuan klasifikasi terbaik, diikuti oleh Logistic Regression dan Random Forest. Nilai AUC yang tinggi pada ketiga model menunjukkan bahwa fitur hasil ekstraksi SqueezeNet memiliki kemampuan yang baik dalam membedakan tingkat kematangan buah jeruk nipis.

### 3.6. Diskusi Penelitian

Hasil penelitian menunjukkan bahwa penggunaan SqueezeNet sebagai feature extractor mampu menghasilkan representasi fitur yang efektif untuk proses klasifikasi tingkat kematangan buah jeruk nipis. Hal ini dibuktikan dengan tingginya performa ketiga algoritma klasifikasi yang diuji, dimana seluruh model memperoleh nilai AUC di atas 0,90, menunjukkan kemampuan yang baik dalam membedakan kelas buah matang dan mentah.

Di antara ketiga algoritma, Artificial Neural Network (ANN) memberikan performa terbaik dengan Accuracy sebesar 95,2% dan AUC sebesar 0,997. Hasil tersebut menunjukkan bahwa ANN lebih mampu mempelajari hubungan nonlinier dari fitur-fitur yang dihasilkan oleh SqueezeNet dibandingkan Logistic Regression maupun Random Forest. Sementara itu, Logistic Regression juga menunjukkan performa yang kompetitif dengan akurasi 94,2%, sehingga dapat menjadi alternatif yang baik karena memiliki model yang lebih sederhana dan mudah diinterpretasikan. Sebaliknya, Random Forest memperoleh akurasi 87,5%, yang mengindikasikan bahwa algoritma berbasis ensemble decision tree kurang optimal dalam memanfaatkan fitur berdimensi tinggi hasil ekstraksi CNN pada dataset penelitian ini.

Hasil visualisasi MDS, Confusion Matrix, dan ROC Curve juga mendukung temuan tersebut. Visualisasi MDS menunjukkan pemisahan kluster yang cukup jelas antara kelas matang dan mentah, sedangkan Confusion Matrix memperlihatkan bahwa ANN menghasilkan jumlah kesalahan klasifikasi paling sedikit. Selain itu, kurva ROC menunjukkan bahwa ANN memiliki kemampuan diskriminasi terbaik dengan nilai AUC yang mendekati 1.

## 4. Kesimpulan

Penelitian ini berhasil menerapkan SqueezeNet sebagai metode ekstraksi fitur dan membandingkan kinerja tiga algoritma klasifikasi, yaitu Artificial Neural Network (ANN), Logistic Regression (LR), dan Random Forest (RF), untuk mengidentifikasi tingkat kematangan buah jeruk nipis. Hasil pengujian menggunakan 10-Fold Cross Validation menunjukkan bahwa seluruh algoritma memiliki performa yang baik, dengan nilai AUC di atas 0,90. Berdasarkan hasil evaluasi, Artificial Neural Network memberikan performa terbaik dengan Accuracy sebesar 95,2%, Precision sebesar 95,3%, Recall sebesar 95,2%, F1-Score sebesar 95,2%, dan AUC sebesar 0,997. Logistic Regression menempati urutan kedua dengan akurasi 94,2%, sedangkan Random Forest memperoleh akurasi 87,5%. Hasil tersebut menunjukkan bahwa kombinasi SqueezeNet sebagai feature extractor dan Artificial Neural Network sebagai algoritma klasifikasi merupakan pendekatan yang paling efektif dalam mengklasifikasikan tingkat kematangan buah jeruk nipis pada dataset penelitian ini. Penelitian selanjutnya dapat menggunakan jumlah dataset yang lebih besar serta melibatkan variasi kondisi pencahayaan, latar belakang, dan sudut pengambilan gambar agar model memiliki kemampuan generalisasi yang lebih baik terhadap kondisi nyata. Selain itu, penelitian berikutnya dapat membandingkan SqueezeNet dengan arsitektur deep learning lainnya, seperti MobileNetV2, EfficientNet, atau ResNet, serta mengevaluasi algoritma klasifikasi tambahan untuk memperoleh performa yang lebih optimal. Pengembangan sistem ke dalam bentuk aplikasi berbasis mobile atau web juga dapat menjadi langkah implementasi untuk mendukung proses identifikasi tingkat kematangan buah secara otomatis di lapangan.

## Referensi

- [1] M. Rizzo, M. Marcuzzo, A. Zangari, A. Gasparetto, and A. Albarelli, "Fruit Ripeness Classification: A Survey," *Artif. Intell. Agric.*, vol. 7, pp. 44–57, 2023, doi: 10.1016/j.aiia.2023.02.004.
- [2] I. D. Apostolopoulos, M. Tzani, and S. I. Aznaouridis, "A General Machine Learning Model for Assessing Fruit Quality Using Deep Image Features," *AI*, vol. 4, no. 4, pp. 812–830, 2023, doi: 10.3390/ai4040041.
- [3] S. Yadav, S. K. Jain, D. Rajpurohit, K. K. Meena, and K. Jain, "Fruit Maturity Detection Using Deep Learning: An Overview," *Int. J. Adv. Biochem. Res.*, vol. 8, no. 7, pp. 608–610, 2024, doi: 10.33545/26174693.2024.v8.i7Sh.1597.
- [4] N. Aherwadi and U. Mittal, "Fruit Quality Identification Using Image Processing, Machine Learning, and Deep Learning: A Review," *Adv. Appl. Math. Sci.*, vol. 21, no. 5, pp. 2645–2660, 2022.
- [5] F. Xiao, H. Wang, Y. Xu, and Z. Shi, "A Lightweight Detection Method for Blueberry Fruit Maturity Based on an Improved YOLOv5

- Algorithm,” *Agriculture*, vol. 14, no. 1, p. 36, 2024, doi: 10.3390/agriculture14010036.
- [6] W. Shafik, A. Tufail, C. D. S. Liyanage, and R. A. A. H. M. Apong, “Using Transfer Learning-Based Plant Disease Classification and Detection for Sustainable Agriculture,” *BMC Plant Biol.*, vol. 24, p. 136, 2024, doi: 10.1186/s12870-024-04825-y.
- [7] S. Siagian, K. Ibnutama, and R. Mahyuni, “Implementasi Metode Ekstraksi Ciri Warna Untuk Mendeteksi Kematangan Buah Jeruk,” *J. Sist. Inf. TGD*, vol. 1, no. 6, pp. 898–905, 2022, [Online]. Available: <https://ojs.trigunadharma.ac.id/index.php/jsi>
- [8] B. Yanto, E. Rouza, L. Fimawahib, B. H. Hayadi, and R. R. Pratama, “Penerapan Algoritma Deep Learning Convolutional Neural Network dalam Menentukan Kematangan Buah Jeruk Manis Berdasarkan Citra Red Green Blue (RGB),” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 10, no. 1, pp. 59–66, 2023, doi: 10.25126/jtiik.2023105695.
- [9] D. A. Sitorus and R. Aulia, “Analisis Tingkat Kematangan Buah Jeruk Menggunakan Chain Code dan K-Nearest Neighbor (KNN) Berbasis Website,” *Algoritma. J. Ilmu Komput. Inform.*, vol. 9, no. 2, pp. 84–99, 2025, doi: 10.30829/algoritma.v9i2.258998.
- [10] Mualfah and others, “Klasifikasi Tingkat Kematangan Jeruk Lemon Menggunakan Support Vector Machine dan Naive Bayes,” *SEIS*, 2025.
- [11] Sitorus and Aulia, “Klasifikasi Tingkat Kematangan Jeruk Menggunakan K-Nearest Neighbor Berbasis HSV dan Shape Feature,” *J. Sist. Inf.*, 2025.
- [12] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. MIT Press, 2016.
- [13] B. Zhou, K. Wu, and M. Chen, “Detection of Gannan Navel Orange Ripeness in Natural Environment Based on YOLOv5-NMM,” *Agronomy*, vol. 14, no. 5, p. 910, 2024, doi: 10.3390/agronomy14050910.
- [14] S. M. M. R. Swapno, S. M. N. Nobel, M. B. Islam, P. Bhattacharya, and E. A. Mattar, “ViT-SENet-Tom: Machine Learning-Based Novel Hybrid Squeeze--Excitation Network and Vision Transformer Framework for Tomato Fruits Classification,” *Neural Comput. Appl.*, vol. 37, pp. 6583–6600, 2025, doi: 10.1007/s00521-025-10973-5.
- [15] A. Amin and others, “Automatic Fruits Freshness Classification Using CNN and Transfer Learning,” *Appl. Sci.*, 2023.
- [16] D. W. Hosmer, S. Lemeshow, and R. X. Sturdivant, *Applied Logistic Regression*, 3rd ed. Wiley, 2013.
- [17] F. Iandola, S. Han, M. Moskewicz, K. Ashraf, W. J. Dally, and K. Keutzer, “SqueezeNet: AlexNet-Level Accuracy with 50x Fewer Parameters and Less than 0.5 MB Model Size,” *arXiv Prepr. arXiv1602.07360*, 2016.
- [18] L. Breiman, “Random forests,” *Mach. Learn.*, vol. 45, pp. 5–32, 2001.