

Klasifikasi Kematangan Buah Pinang (*Areca catechu L.*) Menggunakan Hybrid Deep Feature Fusion dan XGBoost

Anggi Pranata¹, Nelly Khairani Daulay^{2,*}, Ahmad Sobri¹

¹ Fakultas Ilmu Teknik, Program Studi Informatika, Universitas Bina Insan, Lubuklinggau, Indonesia

² Fakultas Ilmu Teknik, Program Studi Rekayasa Sistem Komputer, Universitas Bina Insan, Lubuklinggau, Indonesia

Email: ¹anggi291022@gmail.com, ^{2,*}nellydaulay@univbinainsan.ac.id, ³ahmadsobri506@gmail.com

Email Penulis Corresponding nellydaulay@univbinainsan.ac.id

Abstrak- Kematangan buah pinang (*Areca catechu L.*) merupakan salah satu faktor yang memengaruhi kualitas hasil panen. Proses identifikasi tingkat kematangan secara visual masih memiliki keterbatasan karena dapat dipengaruhi oleh subjektivitas pengamat dan kondisi lingkungan. Penelitian ini bertujuan melakukan klasifikasi tingkat kematangan buah pinang menggunakan pendekatan Hybrid Deep Feature Fusion dengan kombinasi ResNet50 dan EfficientNetB0 sebagai ekstraktor fitur serta XGBoost sebagai algoritma klasifikasi. Dataset yang digunakan merupakan dataset primer sebanyak 1.200 citra buah pinang yang terdiri dari tiga kategori, yaitu mentah, setengah matang, dan matang. Tahapan penelitian meliputi pra-pemrosesan citra, ekstraksi fitur menggunakan CNN, penggabungan fitur menggunakan metode feature concatenation, klasifikasi menggunakan XGBoost, serta evaluasi menggunakan accuracy, precision, recall, F1-score, confusion matrix, dan 5-Fold Cross Validation. Hasil pengujian menunjukkan bahwa ResNet50 + XGBoost dan Hybrid Deep Feature Fusion + XGBoost memperoleh nilai accuracy, precision, recall, dan F1-score sebesar 100%, sedangkan EfficientNetB0 + XGBoost memperoleh accuracy sebesar 99,16%. Hasil tersebut menunjukkan bahwa fitur CNN mampu merepresentasikan karakteristik visual buah pinang pada dataset yang digunakan. Penggunaan Hybrid Deep Feature Fusion memberikan analisis terhadap kombinasi fitur dari dua arsitektur CNN, meskipun peningkatan jumlah fitur tidak selalu memberikan peningkatan nilai evaluasi apabila fitur tunggal telah mampu merepresentasikan karakteristik dataset dengan baik. Pengembangan selanjutnya dapat dilakukan dengan menambahkan variasi dataset untuk mengevaluasi kemampuan generalisasi metode pada kondisi lingkungan yang lebih beragam.

Kata Kunci: Buah Pinang; Klasifikasi Citra; Deep Learning; Hybrid Deep Feature Fusion; XGBoost

Abstract- Areca nut (*Areca catechu L.*) maturity is one of the factors affecting harvest quality. Visual maturity identification still has limitations because it can be influenced by observer subjectivity and environmental conditions. This study aims to classify areca nut maturity levels using a Hybrid Deep Feature Fusion approach by combining ResNet50 and EfficientNetB0 as feature extractors with XGBoost as the classification algorithm. The dataset used in this study was a primary dataset consisting of 1,200 areca nut images categorized into three maturity classes: unripe, semi-ripe, and ripe. The research stages included image preprocessing, feature extraction using CNN models, feature combination through feature concatenation, classification using XGBoost, and performance evaluation using accuracy, precision, recall, F1-score, confusion matrix, and 5-Fold Cross Validation. The experimental results showed that ResNet50 + XGBoost and Hybrid Deep Feature Fusion + XGBoost achieved accuracy, precision, recall, and F1-score values of 100%, while EfficientNetB0 + XGBoost achieved an accuracy of 99.16%. These results indicate that CNN-based features are able to represent the visual characteristics of areca nut images in the dataset used. The Hybrid Deep Feature Fusion approach provides an analysis of feature combination from two different CNN architectures, although increasing the feature dimensions does not always improve evaluation performance when a single feature extractor is already capable of representing dataset characteristics effectively. Future research can be conducted by increasing dataset variations to evaluate the generalization capability of the method under more diverse environmental conditions.

Keywords: Areca Nut; Image Classification; Deep Learning; Hybrid Deep Feature Fusion; XGBoost

1. PENDAHULUAN

Buah pinang (*Areca catechu L.*) merupakan salah satu komoditas perkebunan yang memiliki nilai ekonomi dan dimanfaatkan dalam berbagai sektor industri. Kualitas buah pinang dipengaruhi oleh tingkat kematangannya karena berkaitan dengan karakteristik fisik, kandungan senyawa, serta standar kualitas hasil panen. Oleh karena itu, proses identifikasi tingkat kematangan menjadi salah satu tahapan penting dalam kegiatan pascapanen untuk mendukung pengelompokan kualitas buah yang dihasilkan.

Pada praktiknya, identifikasi tingkat kematangan buah pinang masih banyak dilakukan melalui pengamatan visual berdasarkan perubahan warna dan karakteristik permukaan buah. Pendekatan tersebut relatif mudah diterapkan, namun memiliki keterbatasan karena hasil penilaian dapat dipengaruhi oleh subjektivitas manusia, pengalaman pengamat, serta kondisi lingkungan pada saat proses identifikasi dilakukan. Permasalahan serupa juga ditemukan pada klasifikasi tingkat kematangan berbagai jenis buah, sehingga pengembangan sistem berbasis citra digital menjadi salah satu pendekatan yang banyak dikaji untuk mendukung proses identifikasi secara lebih konsisten[1], [2]. Perkembangan teknologi computer vision berbasis kecerdasan buatan memberikan peluang dalam pengembangan sistem analisis citra pada bidang pertanian. teknologi yang memungkinkan sistem komputer memperoleh dan menginterpretasikan informasi dari citra digital untuk mendukung proses pengenalan objek, analisis pola visual, dan klasifikasi citra secara otomatis[3]. Pemanfaatan computer vision telah banyak diterapkan dalam analisis kualitas produk pertanian, pemantauan tanaman, serta klasifikasi objek berbasis citra[4], [5], [6].

Perkembangan metode deep learning semakin memperluas kemampuan sistem dalam melakukan klasifikasi citra secara otomatis. Salah satu pendekatan yang banyak digunakan adalah Convolutional Neural Network (CNN) karena mampu melakukan proses ekstraksi fitur visual secara otomatis tanpa memerlukan perancangan fitur secara manual. Deep learning memungkinkan sistem membangun representasi fitur secara bertingkat melalui beberapa lapisan jaringan sehingga dapat digunakan untuk memahami pola visual yang kompleks[7]. Pada bidang pertanian, CNN telah diterapkan untuk berbagai tugas analisis citra seperti identifikasi objek, klasifikasi kualitas produk, dan pengenalan karakteristik visual buah berdasarkan citra digital[8], [9]. Berbagai arsitektur CNN telah dikembangkan dengan mekanisme pembelajaran fitur yang berbeda. ResNet50 merupakan salah satu arsitektur CNN yang menerapkan konsep residual learning melalui mekanisme skip connection sehingga memungkinkan proses pembelajaran fitur pada jaringan yang lebih dalam [10]. Selain itu, EfficientNetB0 menggunakan pendekatan compound scaling yang mengatur keseimbangan antara kedalaman jaringan, lebar jaringan, dan resolusi citra dalam proses pembentukan representasi fitur [11]. Perbedaan karakteristik arsitektur tersebut memungkinkan setiap model menghasilkan representasi fitur visual yang berbeda.

Beberapa penelitian sebelumnya telah menerapkan pendekatan berbasis deep learning untuk klasifikasi dan analisis kematangan buah. [1] melakukan kajian terhadap penerapan kecerdasan buatan dalam klasifikasi tingkat kematangan buah dan menunjukkan bahwa karakteristik visual seperti warna, bentuk, dan tekstur menjadi informasi penting dalam proses identifikasi. Penerapan metode berbasis deep learning juga telah digunakan pada komoditas perkebunan lain, seperti penelitian deteksi kematangan buah kelapa sawit menggunakan citra digital yang menunjukkan kemampuan model dalam mengenali karakteristik visual tingkat kematangan buah[12]. [2] menerapkan metode deep learning untuk klasifikasi serta penilaian kematangan buah dan sayuran menggunakan citra digital. [13]. juga melakukan penelitian terkait identifikasi kematangan buah menggunakan citra digital berbasis deep learning. Selain itu, [14] menerapkan pendekatan deep learning pada identifikasi tingkat kematangan buah kelapa sawit yang menunjukkan pemanfaatan metode berbasis citra pada komoditas perkebunan.

Pada komoditas buah pinang, penelitian berbasis kecerdasan buatan juga mulai dikembangkan. [15] menyediakan dataset citra buah pinang untuk mendukung pengembangan metode berbasis deep learning. Selain itu, [16] menerapkan model deep learning untuk melakukan klasifikasi buah pinang berdasarkan karakteristik citra digital. Penelitian tersebut menunjukkan bahwa pendekatan berbasis citra dapat digunakan dalam proses identifikasi karakteristik visual buah pinang. Namun, eksplorasi terhadap kombinasi fitur dari beberapa arsitektur CNN pada klasifikasi tingkat kematangan buah pinang masih dapat dikaji lebih lanjut.

Meskipun CNN mampu menghasilkan representasi fitur dari citra, penggunaan satu arsitektur ekstraksi fitur menghasilkan informasi berdasarkan karakteristik pembelajaran model tertentu. Oleh karena itu, beberapa penelitian mengembangkan pendekatan penggabungan fitur (feature fusion) untuk memanfaatkan informasi yang diperoleh dari beberapa model ekstraksi fitur. [17] menerapkan penggabungan fitur dari beberapa model CNN pralatih untuk mengombinasikan representasi fitur yang diperoleh dari masing-masing model. Pendekatan multi-scale feature fusion juga telah digunakan untuk meningkatkan representasi fitur pada proses klasifikasi citra[18]. [19] juga menerapkan pendekatan multi-CNN deep feature fusion dengan memanfaatkan kombinasi fitur dari beberapa arsitektur CNN sebelum dilakukan proses klasifikasi.

Pendekatan feature fusion memungkinkan fitur dari beberapa model digunakan secara bersama dalam proses klasifikasi sehingga karakteristik representasi dari arsitektur berbeda dapat dianalisis. Namun, efektivitas penggabungan fitur tidak hanya bergantung pada jumlah fitur yang digunakan, tetapi juga dipengaruhi oleh karakteristik dataset, kualitas representasi fitur, serta metode klasifikasi yang diterapkan.

Berdasarkan kajian penelitian sebelumnya, terdapat beberapa aspek yang masih dapat dikembangkan. Penelitian terkait klasifikasi kematangan buah pinang menggunakan deep learning masih lebih terbatas dibandingkan beberapa komoditas pertanian lainnya. Selain itu, penelitian yang mengevaluasi kombinasi fitur dari ResNet50 dan EfficientNetB0 sebagai ekstraktor fitur dengan algoritma XGBoost pada klasifikasi kematangan buah pinang masih belum banyak dilakukan.

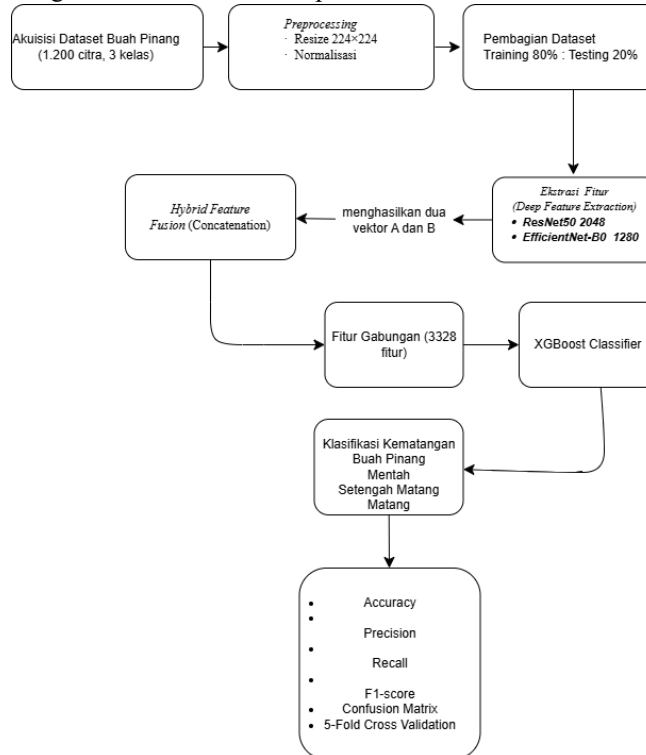
Berdasarkan permasalahan tersebut, penelitian ini menerapkan pendekatan Hybrid Deep Feature Fusion untuk klasifikasi tingkat kematangan buah pinang. Metode yang digunakan menggabungkan fitur hasil ekstraksi ResNet50 dan EfficientNetB0 menggunakan proses feature concatenation, kemudian fitur hasil penggabungan digunakan sebagai masukan pada algoritma XGBoost untuk proses klasifikasi[20]. Penelitian ini bertujuan untuk mengevaluasi pemanfaatan kombinasi representasi fitur CNN dalam klasifikasi tingkat kematangan buah pinang pada tiga kategori, yaitu mentah, setengah matang, dan matang.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini menerapkan pendekatan Hybrid Deep Feature Fusion untuk melakukan klasifikasi tingkat kematangan buah pinang (*Areca catechu* L.) berdasarkan citra digital. Secara umum, tahapan penelitian terdiri dari proses akuisisi dataset, pra-pemrosesan citra, ekstraksi fitur menggunakan model Convolutional Neural Network (CNN),

penggabungan fitur (feature fusion), klasifikasi menggunakan XGBoost, serta evaluasi performa model. Penggunaan citra digital pada penelitian ini bertujuan untuk memperoleh informasi visual buah pinang berdasarkan karakteristik yang dapat diamati, seperti warna dan tekstur permukaan. Pendekatan berbasis computer vision telah banyak digunakan dalam bidang pertanian karena mampu melakukan analisis informasi visual objek berdasarkan citra digital [5]. Pada penelitian ini, model CNN digunakan sebagai ekstraktor fitur, bukan sebagai model klasifikasi akhir. Fitur yang diperoleh dari ResNet50 dan EfficientNetB0 digunakan sebagai representasi visual citra buah pinang yang selanjutnya menjadi masukan pada algoritma XGBoost untuk proses klasifikasi.



Gambar 1. Tahapan penelitian klasifikasi kematangan buah pinang menggunakan Hybrid Deep Feature Fusion dan XGBoost

Gambar 1 menunjukkan alur penelitian yang dilakukan. Dataset citra buah pinang terlebih dahulu melalui tahap pra-pemrosesan. Selanjutnya, citra diproses menggunakan dua model CNN untuk memperoleh representasi fitur. Fitur dari kedua model kemudian digabungkan dan digunakan sebagai data masukan pada algoritma XGBoost. Tahap terakhir adalah evaluasi untuk mengetahui performa model terhadap dataset pengujian.

2.2 Akuisisi Dataset

Dataset yang digunakan merupakan dataset primer yang diperoleh melalui proses pengambilan citra buah pinang secara langsung di Desa Sukaraya Baru, Kecamatan STL Ulu Terawas, Kabupaten Musi Rawas, Sumatera Selatan pada tahun 2025. Proses akuisisi citra dilakukan menggunakan kamera smartphone Realme Note 60. Dataset terdiri dari tiga kategori tingkat kematangan buah pinang, yaitu mentah, setengah matang, dan matang. Penentuan kelas dilakukan berdasarkan karakteristik visual buah yang terlihat pada perubahan warna permukaan. Jumlah keseluruhan dataset sebanyak 1.200 citra dengan distribusi yang seimbang pada masing-masing kelas.

Tabel 1. Distribusi Dataset Buah Pinang

Kelas	Jumlah Kelas
Mentah	400
Setengah Matang	400
Matang	400
Total	1200

Berdasarkan Tabel 1, setiap kategori tingkat kematangan memiliki jumlah citra yang sama yaitu 400 citra. Distribusi dataset yang seimbang digunakan untuk mengurangi pengaruh ketidakseimbangan jumlah sampel antar kelas selama proses pelatihan model. Namun, distribusi yang seimbang belum sepenuhnya merepresentasikan seluruh variasi kondisi nyata, sehingga pengembangan dataset dengan variasi pencahayaan, latar belakang, dan kondisi pengambilan citra yang lebih luas masih diperlukan pada penelitian selanjutnya.



Gambar 2. Contoh dataset buah pinang berdasarkan tingkat kematangan

Gambar 2 menunjukkan contoh citra buah pinang berdasarkan tiga kategori tingkat kematangan. Dataset tersebut digunakan sebagai dasar dalam proses pelatihan dan pengujian metode yang diterapkan. Meskipun dataset memiliki distribusi kelas yang seimbang, citra masih diperoleh pada kondisi pengambilan tertentu sehingga variasi lingkungan yang lebih luas menjadi aspek yang dapat dikembangkan pada penelitian berikutnya.

2.3 Pra-Pemrosesan Data

Tahap pra-pemrosesan dilakukan untuk menyesuaikan citra agar dapat digunakan pada model ekstraksi fitur CNN. Seluruh citra diubah ukurannya menjadi 224×224 piksel sesuai dengan ukuran input yang digunakan pada ResNet50 dan EfficientNetB0. Selain itu, dilakukan normalisasi nilai piksel untuk menyeragamkan skala data sehingga citra dapat diproses oleh model deep learning[8]. Dataset kemudian dibagi menjadi data pelatihan (training data) dan data pengujian (testing data) menggunakan rasio 80:20. Sebanyak 960 citra digunakan sebagai data pelatihan dan 240 citra digunakan sebagai data pengujian.

2.4 Ekstraksi Fitur Menggunakan ResNet50

ResNet50 digunakan sebagai salah satu model ekstraksi fitur pada penelitian ini. Arsitektur ResNet memperkenalkan konsep residual learning dengan mekanisme skip connection yang memungkinkan proses pembelajaran fitur pada jaringan yang memiliki banyak lapisan[10]. Pada penelitian ini, ResNet50 digunakan tanpa lapisan klasifikasi akhir (fully connected layer) sehingga keluaran yang diperoleh berupa vektor fitur. Fitur tersebut kemudian digunakan sebagai representasi karakteristik visual buah pinang dalam proses klasifikasi.

2.5 Ekstraksi Fitur Menggunakan EfficientNetB0

EfficientNetB0 digunakan sebagai model ekstraksi fitur kedua. Arsitektur EfficientNet menerapkan pendekatan compound scaling yang mengatur keseimbangan antara kedalaman jaringan, lebar jaringan, dan resolusi citra [11]. Penggunaan EfficientNetB0 bertujuan memperoleh representasi fitur dari arsitektur CNN yang berbeda. Hal ini dilakukan karena setiap model CNN memiliki mekanisme pembelajaran fitur yang dapat menghasilkan karakteristik representasi visual berbeda terhadap suatu citra.

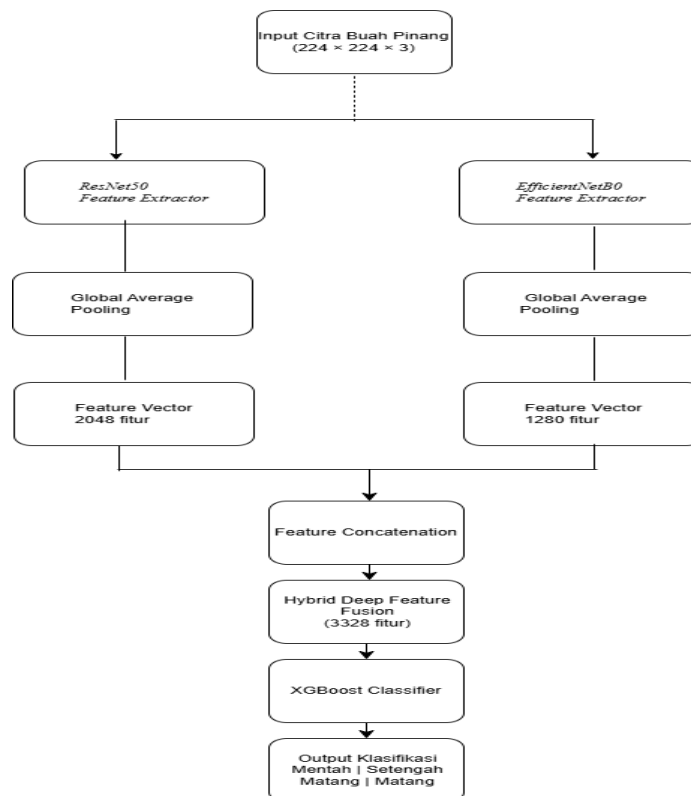
2.6 Hybrid Deep Feature Fusion

Tahap feature fusion dilakukan dengan menggabungkan fitur hasil ekstraksi dari ResNet50 dan EfficientNetB0 menggunakan metode concatenation. Pendekatan ini digunakan untuk mengombinasikan representasi fitur yang diperoleh dari beberapa model ekstraksi fitur sehingga karakteristik dari arsitektur CNN yang berbeda dapat dianalisis secara bersama[17], [19].

Proses penggabungan fitur pada penelitian ini dinyatakan sebagai:

$$F_{fusion} = [F_{ResNet50}, F_{EfficientNetB0}] \quad (1)$$

Keterangan: F_{fusion} merupakan fitur hasil penggabungan, $F_{ResNet50}$ merupakan fitur hasil ekstraksi ResNet50, dan $F_{EfficientNetB0}$ merupakan fitur hasil ekstraksi EfficientNetB0.



Gambar 3. Arsitektur Hybrid Deep Feature Fusion

Gambar 3 menunjukkan arsitektur Hybrid Deep Feature Fusion yang digunakan dalam penelitian ini. Citra buah pinang yang telah melalui tahap pra-pemrosesan digunakan sebagai input pada dua model CNN, yaitu ResNet50 dan EfficientNetB0. Kedua model tersebut digunakan sebagai ekstraktor fitur berdasarkan karakteristik masing-masing arsitektur. Fitur dari ResNet50 sebanyak 2.048 fitur dan EfficientNetB0 sebanyak 1.280 fitur digabungkan menggunakan metode feature concatenation sehingga menghasilkan fitur gabungan sebanyak 3.328 fitur. Selanjutnya, fitur hasil penggabungan digunakan sebagai masukan algoritma XGBoost untuk klasifikasi tingkat kematangan buah pinang.mentang.

2.7 Klasifikasi Menggunakan XGBoost

Tahap klasifikasi dilakukan menggunakan algoritma XGBoost. XGBoost merupakan algoritma berbasis gradient boosting yang membangun beberapa model pohon keputusan secara bertahap untuk menghasilkan prediksi akhir[20]. Pada penelitian ini, XGBoost digunakan untuk melakukan klasifikasi terhadap fitur hasil ekstraksi CNN ke dalam tiga kategori tingkat kematangan buah pinang yaitu mentah, setengah matang, dan matang.

2.8 Evaluasi Model

Evaluasi dilakukan untuk mengetahui performa model terhadap data pengujian. Parameter evaluasi yang digunakan terdiri dari accuracy, precision, recall, F1-score, classification report, dan confusion matrix. Selain itu, pengujian menggunakan 5-Fold Cross Validation dilakukan untuk melihat konsistensi performa model pada beberapa pembagian data. Evaluasi yang dilakukan bertujuan untuk menganalisis performa metode pada dataset penelitian. Namun, pengujian menggunakan dataset dengan kondisi pengambilan citra yang lebih beragam tetap diperlukan untuk mengetahui kemampuan generalisasi metode pada kondisi yang berbeda.

3. HASIL DAN PEMBAHASAN

Bagian ini menjelaskan hasil pengujian metode klasifikasi tingkat kematangan buah pinang (*Areca catechu* L.) menggunakan pendekatan Hybrid Deep Feature Fusion dengan kombinasi ResNet50 dan EfficientNetB0 sebagai ekstraktor fitur serta XGBoost sebagai algoritma klasifikasi. Evaluasi dilakukan untuk menganalisis kemampuan representasi fitur yang diperoleh dari model CNN dalam membedakan karakteristik visual pada tiga kategori

kematangan buah pinang. Pengujian dilakukan menggunakan dataset sebanyak 1.200 citra buah pinang yang telah melalui tahap pra-pemrosesan. Dataset dibagi menjadi data pelatihan sebesar 80% dan data pengujian sebesar 20%. Data pengujian digunakan untuk mengevaluasi kemampuan model terhadap citra yang tidak digunakan pada proses pelatihan. Pemanfaatan metode berbasis deep learning pada analisis citra pertanian telah banyak dikembangkan karena kemampuannya dalam memperoleh representasi fitur visual secara otomatis. Namun, performa model tetap dipengaruhi oleh karakteristik dataset yang digunakan, seperti jumlah data, variasi objek, kualitas citra, dan kondisi pengambilan gambar[1], [2].

3.1 Hasil Ekstraksi Fitur

Tahap ekstraksi fitur dilakukan menggunakan dua arsitektur CNN, yaitu ResNet50 dan EfficientNetB0. Kedua model digunakan sebagai feature extractor, sehingga lapisan klasifikasi akhir tidak digunakan dalam proses pengujian. ResNet50 menghasilkan representasi fitur sebanyak 2.048 fitur untuk setiap citra buah pinang. Arsitektur ini menggunakan konsep residual learning yang memungkinkan proses pembelajaran representasi fitur melalui jaringan yang lebih dalam[10]. Sementara itu, EfficientNetB0 menghasilkan representasi sebanyak 1.280 fitur. Perbedaan jumlah fitur yang diperoleh disebabkan oleh perbedaan desain arsitektur dan mekanisme ekstraksi fitur pada masing-masing model[11]. Fitur dari kedua model kemudian digabungkan menggunakan metode feature concatenation sehingga menghasilkan representasi gabungan sebanyak 3.328 fitur.

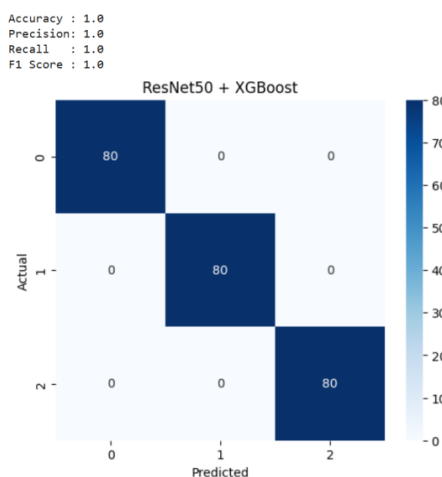
Tabel 2. Jumlah Fitur hasil ekstraksi CNN

Metode	Jumlah Fitur
ResNet50	2048
EfficientNetB0	1280
Hybrid Feature Fusion	3328

Berdasarkan Tabel 2, proses feature fusion menghasilkan dimensi fitur yang lebih besar karena adanya penggabungan dua representasi fitur. Namun, peningkatan jumlah fitur tidak selalu menunjukkan peningkatan performa klasifikasi, karena efektivitas fitur gabungan dipengaruhi oleh relevansi informasi yang diperoleh dari masing-masing ekstraktor fitur. Pendekatan feature fusion pada penelitian ini digunakan untuk mengevaluasi bagaimana kombinasi fitur dari dua model CNN dapat merepresentasikan karakteristik visual buah pinang, bukan sebagai asumsi bahwa fitur gabungan selalu menghasilkan performa lebih tinggi dibandingkan fitur tunggal.

3.2 Hasil Pengujian ResNet50 dan XGBoost

Pengujian pertama dilakukan menggunakan fitur hasil ekstraksi ResNet50 yang kemudian diklasifikasikan menggunakan XGBoost. Pengujian ini digunakan sebagai salah satu pembandingan untuk mengetahui karakteristik fitur yang diperoleh dari satu model CNN.



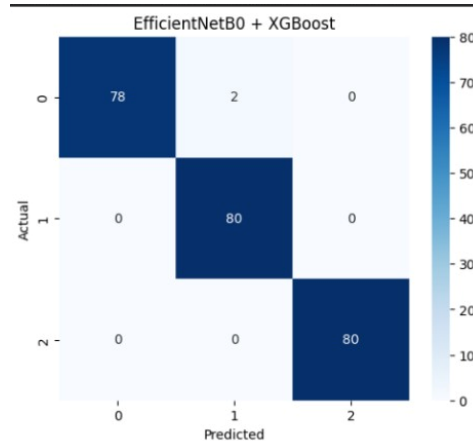
Gambar 4. Confusion Matrix ResNet50 dan XGBoost

Berdasarkan hasil pada Gambar 4, kombinasi ResNet50 dan XGBoost mampu melakukan klasifikasi terhadap data pengujian dengan nilai evaluasi yang tinggi. Hasil tersebut menunjukkan bahwa fitur yang diperoleh dari ResNet50 telah mampu merepresentasikan pola visual pada dataset penelitian. Performa yang diperoleh dapat dipengaruhi oleh

karakteristik dataset, terutama adanya perbedaan visual antar kategori kematangan buah pinang seperti perubahan warna permukaan. Oleh karena itu, hasil yang diperoleh perlu dianalisis berdasarkan ruang lingkup dataset yang digunakan.

3.3 Hasil Pengujian EfficientNetB0 dan XGBoost

Pengujian kedua dilakukan menggunakan fitur EfficientNetB0 sebagai masukan algoritma XGBoost. Pengujian ini dilakukan untuk melihat kemampuan representasi fitur dari arsitektur CNN yang berbeda.




Gambar 5. Confusion Matrix EfficientNetB0 dan XGBoost

Berdasarkan gambar 5, EfficientNetB0 juga mampu menghasilkan fitur yang dapat digunakan dalam proses klasifikasi tingkat kematangan buah pinang. Terdapat sedikit perbedaan nilai evaluasi dibandingkan ResNet50. Perbedaan tersebut menunjukkan bahwa setiap arsitektur CNN memiliki mekanisme berbeda dalam mengekstraksi informasi visual. Oleh karena itu, penggunaan beberapa model ekstraksi fitur dapat digunakan sebagai pendekatan untuk memperoleh variasi representasi fitur.

3.4 Hasil Pengujian Hybrid Deep Feature Fusion dan XGBoost

Pengujian utama dilakukan menggunakan fitur hasil penggabungan ResNet50 dan EfficientNetB0. Fitur dari kedua model digabungkan melalui proses feature fusion sebelum diklasifikasikan menggunakan XGBoost. Pendekatan penggabungan fitur dilakukan karena setiap model CNN dapat memperoleh informasi visual yang berbeda dari suatu citra. Beberapa penelitian sebelumnya menunjukkan bahwa feature fusion dapat digunakan untuk mengombinasikan beberapa sumber fitur dalam analisis citra, meskipun pengaruhnya terhadap performa tetap bergantung pada karakteristik data yang digunakan[15],[16].



Gambar 6. Confusion Matrix Hybrid Deep Feature Fusion dan XGBoost

Berdasarkan Gambar 6, metode Hybrid Deep Feature Fusion dan XGBoost mampu melakukan klasifikasi pada dataset pengujian dengan hasil yang baik. Namun, hasil evaluasi menunjukkan bahwa performa metode ini memiliki nilai yang sama dengan ResNet50 + XGBoost. Kondisi tersebut menunjukkan bahwa pada dataset penelitian ini, fitur tunggal dari ResNet50 telah memiliki kemampuan representasi yang cukup untuk membedakan karakteristik visual antar kelas.

Dengan demikian, kontribusi pendekatan Hybrid Deep Feature Fusion lebih diarahkan pada eksplorasi kombinasi fitur dari beberapa model CNN, bukan pada klaim peningkatan performa dibandingkan seluruh metode tunggal.

3.5 Perbandingan Performa Model

Perbandingan dilakukan terhadap tiga pendekatan yaitu ResNet50 + XGBoost, EfficientNetB0 + XGBoost, dan Hybrid Deep Feature Fusion + XGBoost.

Tabel 3. Perbandingan hasil evaluasi model

Model	Accuracy	Precision	Recall	F1-Score
ResNet50 + XGBoost	100%	100%	100%	100%
EfficientNetB0+ XGBoost	99,16%	99,18%	99,16%	99,16%
Hybrid Feature Fusion + XGBoost	100%	100%	100%	100%

Berdasarkan Tabel 3, ResNet50 + XGBoost dan Hybrid Feature Fusion + XGBoost memperoleh hasil evaluasi yang sama pada dataset pengujian. Hasil ini menunjukkan bahwa penambahan fitur dari EfficientNetB0 pada proses fusion tidak memberikan peningkatan nilai evaluasi dibandingkan ResNet50 dalam skenario pengujian yang digunakan. Meskipun demikian, penggabungan fitur tetap memberikan informasi mengenai bagaimana kombinasi beberapa representasi CNN bekerja pada klasifikasi kematangan buah pinang. Hasil penelitian ini menunjukkan bahwa efektivitas metode tidak hanya dipengaruhi oleh kompleksitas model, tetapi juga oleh karakteristik dataset dan kualitas fitur yang digunakan.

3.6 Validasi Menggunakan 5-Fold Cross Validation

Pengujian tambahan dilakukan menggunakan metode 5-Fold Cross Validation untuk mengetahui konsistensi performa model terhadap variasi pembagian data.

Tabel 4. Hasil 5-Fold Cross Validation

Fold	Accuracy
Fold 1	100%
Fold 2	100%
Fold 3	100%
Fold 4	100%
Fold 5	100%

Tabel 4 Menunjukkan Hasil validasi menunjukkan nilai evaluasi yang konsisten pada dataset yang digunakan. Namun, hasil tersebut tidak dapat dijadikan kesimpulan bahwa model akan menghasilkan performa yang sama pada seluruh kondisi data. Perbedaan lingkungan pengambilan citra, variasi pencahayaan, latar belakang objek, serta karakteristik buah dari lokasi berbeda dapat memengaruhi kemampuan generalisasi model.

3.7 Pembahasan

Berdasarkan keseluruhan hasil pengujian, pendekatan ekstraksi fitur CNN yang dikombinasikan dengan XGBoost dapat digunakan untuk klasifikasi tingkat kematangan buah pinang pada dataset penelitian. Hasil ini sejalan dengan penelitian sebelumnya yang menunjukkan bahwa metode berbasis citra digital dan deep learning dapat diterapkan dalam analisis kualitas produk pertanian[1], [2]

Pada penelitian ini, hasil evaluasi yang tinggi dipengaruhi oleh beberapa faktor, seperti distribusi dataset yang seimbang serta karakteristik visual antar kelas yang cukup berbeda. Oleh karena itu, hasil yang diperoleh perlu dipahami sesuai dengan kondisi dataset yang digunakan.

Keterbatasan penelitian ini terdapat pada variasi dataset yang masih terbatas. Selain pendekatan berbasis citra, penelitian kualitas buah juga dapat dikembangkan dengan mengombinasikan informasi tambahan dari sensor atau karakteristik lain untuk memperoleh analisis kualitas yang lebih komprehensif. Seluruh citra diperoleh menggunakan perangkat kamera dan kondisi pengambilan tertentu, sehingga belum mencakup variasi lingkungan yang lebih kompleks seperti perubahan intensitas cahaya, jenis kamera berbeda, variasi latar belakang, dan kondisi buah dari lokasi berbeda.

Selain itu, penelitian ini hanya mengevaluasi pendekatan berdasarkan fitur visual citra. Faktor lain yang dapat memengaruhi tingkat kematangan buah, seperti karakteristik fisik atau kandungan internal buah, belum dianalisis. Berdasarkan keterbatasan tersebut, penelitian selanjutnya dapat dilakukan dengan memperluas variasi dataset,

melakukan pengujian pada kondisi lingkungan nyata, serta membandingkan pendekatan feature fusion lainnya untuk memperoleh pemahaman yang lebih menyeluruh terhadap klasifikasi kematangan buah pinang.

4. KESIMPULAN

Penelitian ini melakukan klasifikasi tingkat kematangan buah pinang (*Areca catechu* L.) menggunakan pendekatan Hybrid Deep Feature Fusion dengan kombinasi ResNet50 dan EfficientNetB0 sebagai ekstraktor fitur serta XGBoost sebagai algoritma klasifikasi. Dataset yang digunakan merupakan dataset primer sebanyak 1.200 citra buah pinang yang terdiri dari tiga kategori tingkat kematangan yaitu mentah, setengah matang, dan matang. Berdasarkan hasil pengujian, ResNet50 + XGBoost dan Hybrid Deep Feature Fusion + XGBoost memperoleh nilai accuracy, precision, recall, dan F1-score sebesar 100%, sedangkan EfficientNetB0 + XGBoost memperoleh accuracy sebesar 99,16%. Hasil tersebut menunjukkan bahwa fitur yang diperoleh dari CNN mampu merepresentasikan karakteristik visual buah pinang pada dataset penelitian. Penggunaan Hybrid Deep Feature Fusion memberikan analisis terhadap pemanfaatan kombinasi fitur dari dua arsitektur CNN berbeda, meskipun pada pengujian ini penggabungan fitur belum memberikan peningkatan nilai evaluasi dibandingkan penggunaan fitur tunggal ResNet50. Hal tersebut menunjukkan bahwa efektivitas feature fusion dipengaruhi oleh karakteristik dataset dan kualitas fitur yang digunakan. Keterbatasan penelitian ini terdapat pada penggunaan dataset yang masih diperoleh dalam kondisi pengambilan citra tertentu, sehingga variasi pencahayaan, latar belakang, perangkat kamera, dan kondisi lingkungan belum sepenuhnya terwakili. Penelitian selanjutnya dapat dilakukan dengan memperluas jumlah serta variasi dataset, melakukan pengujian pada kondisi lingkungan yang berbeda, dan mengevaluasi metode penggabungan fitur lainnya untuk mengetahui kemampuan generalisasi model secara lebih menyeluruh.

REFERENCES

- [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, Mar. 2023, doi: 10.1016/j.aiia.2023.02.004.
- [2] E. Tapia-Mendez, I. A. Cruz-Albarran, S. Tovar-Arriaga, and L. A. Morales-Hernandez, "Deep Learning-Based Method for Classification and Ripeness Assessment of Fruits and Vegetables," *Appl. Sci.*, vol. 13, no. 22, p. 12504, Nov. 2023, doi: 10.3390/app132212504.
- [3] R. Szeliski, "Computer Vision: Algorithms and Applications, 2nd Edition".
- [4] Z. Huang, D. M. Eugene, X. Li, X. Wang, and X. X. Romeiko, "A comprehensive review of quality measurements of fruits using electronic nose and computer vision," *Clean. Waste Syst.*, vol. 14, p. 100498, Jun. 2026, doi: 10.1016/j.clwas.2026.100498.
- [5] Z. Cao, S. Sun, and X. Bao, "A Review of Computer Vision and Deep Learning Applications in Crop Growth Management," *Appl. Sci.*, vol. 15, no. 15, p. 8438, Jul. 2025, doi: 10.3390/app15158438.
- [6] A. Wang, H. Wu, and Y. Iwahori, "Advances in Computer Vision and Deep Learning and Its Applications," *Electronics*, vol. 14, no. 8, p. 1551, Apr. 2025, doi: 10.3390/electronics14081551.
- [7] A. Betti, M. Gori, and S. Melacci, *Deep Learning to See: Towards New Foundations of Computer Vision*. in SpringerBriefs in Computer Science. Cham: Springer International Publishing, 2022. doi: 10.1007/978-3-030-90987-1.
- [8] M. H. Mozaffari, "Deep Learning for Computer Vision Application," *Electronics*, vol. 14, no. 14, p. 2874, Jul. 2025, doi: 10.3390/electronics14142874.
- [9] Y. Shu, J. Zhang, Y. Wang, and Y. Wei, "Fruit Freshness Classification and Detection Based on the ResNet-101 Network and Non-Local Attention Mechanism," *Foods*, vol. 14, no. 11, p. 1987, Jun. 2025, doi: 10.3390/foods14111987.
- [10] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," Dec. 10, 2015, *arXiv:arXiv:1512.03385*. doi: 10.48550/arXiv.1512.03385.
- [11] M. Tan and Q. V. Le, "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks," Sep. 11, 2020, *arXiv:arXiv:1905.11946*. doi: 10.48550/arXiv.1905.11946.
- [12] L. P. Nur'aini and M. Rahardi, "Detection of Ripeness in Oil Palm Fresh Fruit Bunches Using the YOLO12S Algorithm on Digital Images," vol. 9, no. 4.
- [13] B. Xiao, "Fruit Ripeness Identification From Digital Images Using Deep Learning".
- [14] S. Ashari, G. J. Yanris, and I. Purnama, "Oil Palm Fruit Ripeness Detection using Deep Learning," *Sinkron*, vol. 7, no. 2, pp. 649–656, May 2022, doi: 10.33395/sinkron.v7i2.11420.
- [15] P. M. Naik and B. Rudra, "X-ArecaNet: Dataset of arecanut X-ray images for deep learning applications," *Data Brief*, vol. 61, p. 111721, Aug. 2025, doi: 10.1016/j.dib.2025.111721.
- [16] S. Patil, A. Naik, and J. Parab, "Efficient Deep Learning model for de-husked Areca nut classification," *J. Appl. Nat. Sci.*, vol. 15, no. 4, pp. 1529–1540, Dec. 2023, doi: 10.31018/jans.v15i4.5067.
- [17] H. O. Ilhan, G. Serbes, and N. Aydin, "Decision and feature level fusion of deep features extracted from public COVID-19 data-sets," *Appl. Intell.*, vol. 52, no. 8, pp. 8551–8571, Jun. 2022, doi: 10.1007/s10489-021-02945-8.
- [18] "MSFF: Multi-Scale feature fusion for fine-grained image classification," *Acad. J. Comput. Inf. Sci.*, vol. 6, no. 2, 2023, doi: 10.25236/AJCIS.2023.060215.
- [19] K. Pañç and S. Sekmen, "Multi-CNN Deep Feature Fusion and Stacking Ensemble Classifier for Breast Ultrasound Lesion Classification," *Forbes J. Med.*, Jul. 2025, doi: 10.4274/forbes.galenos.2025.02360.



- [20] T. Chen and C. Guestrin, “XGBoost: A Scalable Tree Boosting System,” in *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, San Francisco California USA: ACM, Aug. 2016, pp. 785–794. doi: 10.1145/2939672.2939785.

